

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Luka Bubalo

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Prof. dr. sc. Dragutin Lisjak, dipl. ing.

Student:

Luka Bubalo

Zagreb, 2018.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se prof. dr. sc. Dragutinu Lisjaku na ukazanom povjerenju, pomoći i savjetima tijekom izrade rada.

Također, zahvaljujem se zaposlenicima tvrtke "Konzum" koji su mi svojim savjetima pomogli pri provođenju ciljeva diplomskog zadatka.

Želim zahvaliti svojoj obitelji, kao i svima koji su mi na bilo koji način pomogli tijekom studija.

Luka Bubalo



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa:	
Ur. broj:	

DIPLOMSKI ZADATAK

Student: **LUKA BUBALO**

Mat. br.: 0035192387

Naslov rada na hrvatskom jeziku: **Optimiranje vremena istovara robe distributivnog centra**

Naslov rada na engleskom jeziku: **The goods unloading time optimization of the distribution center**

Opis zadatka:

Distributivni centri prvenstveno imaju zadaću pravovremene opskrbe svojih prodavaonica svježim proizvodima. Kako bi to radili na učinkovit način bitno je kvalitetno planiranje vremena dostave robe kako bi se smanjili troškovi čekanja istovara robe. Jedan od većih problema je predvidjeti vremena trajanja istovara robe iz dostavnih vozila (kamiona) dobavljača kako se ne bi stvarala „uska grla“ ostalim procesima skladištenja robe te u konačnici dolazilo do kašnjenja s dostavom robe na prodajna mjesta (prodavaonice). Sukladno navedenom, u radu je potrebno:

1. Opisati načine skladištenja i otpreme robe u distributivnom centru.
2. Mapirati, vizualizirati i analizirati aktivnosti trajanja procesa dostave i istovara robe distributivnog centra. Predložiti poboljšanja procesa.
3. Dokazati ili opovrgnuti statističku hipotezu postojanja korelacije vremena istovara u zavisnosti od vrste robe, načina pakiranja, istovarne površine ili sličnih značajki dostavljene robe.
4. Predložiti i kreirati model predviđanja vremena istovara robe te rad istog provjeriti u konkretnom distributivnom centru. Za kreiranje matematičkog modela primijeniti statističke ili metode strojnog učenja.
5. Analizom dobivenih rezultata izvesti zaključke.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:
27. rujna 2018.

Rok predaje rada:
29. studenog 2018.

Predviđeni datum obrane:
05. prosinca 2018.
06. prosinca 2018.
07. prosinca 2018.

Zadatak zadao:
prof. dr. sc. Dragutin Lisjak

Predsjednica Povjerenstva:
prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	II
POPIS TABLICA.....	IV
POPIS OZNAKA	V
SAŽETAK.....	VI
SUMMARY	VII
1. UVOD.....	1
2. LOGISTIČKO DISTRIBUTIVNI CENTAR	3
2.1. Značajke „Konzum“ depozitnog skladišta	6
3. MAPIRANJE PROCESA.....	10
3.1. Relacijske mape	10
3.2. Međufunkcionalni dijagram toka	12
3.3. Osnovni dijagram toka	14
3.4. Mapiranje procesa na primjeru „Konzum“ depozitnog skladišta	15
4. ISTOVAR I PREUZIMANJE ROBE.....	17
4.1. Trajanje procesa istovara u depozitnom skladištu	17
4.2. Analiza prikupljenih podataka o trajanju procesa istovara	20
4.3. Izrada modela predviđanja trajanja procesa istovara	24
4.4. Testiranje utjecaja dobavljača na vrijeme trajanja istovara	26
4.5. Optimizacija parametara i modela predviđanja trajanja istovara.....	29
4.5.1. Testiranje normalnosti podataka	37
4.5.2. Analiza varijance izmjerenog trajanja procesa istovara i modela predviđanja ...	38
4.6. Trajanje procesa preuzimanja u depozitnom skladištu	42
4.7. Izračun broja paletnih mjesta	45
4.8. Analiza prikupljenih podataka o trajanju procesa preuzimanja	55
4.9. Izrada modela predviđanja trajanja preuzimanja	63
5. MODEL PREDVIĐANJA TRAJANJA PROCESA.....	72
5.1. Pregled otpremnice, dodjela istovarne rampe i dolazak vozača na istovarnu rampu.	72
5.2. Istovar robe	73
5.3. Preuzimanje robe (fizičko zaprimanje i sistemsko zaprimanje)	73
5.4. Ukupno trajanje procesa.....	73
6. ZAKLJUČAK.....	75
LITERATURA.....	76
PRILOZI.....	77

POPIS SLIKA

Slika 1.	Cross - docking shema[2].....	4
Slika 2.	Logističko distributivni centar „Konzum“ [3].....	4
Slika 3.	Konsolidacija proizvoda [1]	5
Slika 4.	Pregrupiranje proizvoda[1].....	6
Slika 5.	Prikaz regala u depozitnom skladištu	7
Slika 6.	Električni viličar	8
Slika 7.	Ručni RF skener	8
Slika 8.	Osnovni predložak za relacijsku mapu[4]	11
Slika 9.	Relacijska mapa-ključne značajke: (A) dobavljač-organizacija-kupac komponente, (B) dio/cjelina odnos, (C) dobavljač-kupac odnos[4]	12
Slika 10.	Glavne značajke međufunkcionalnog dijagrama toka[4]	13
Slika 11.	Glavne značajke osnovnog dijagrama toka[4]	14
Slika 12.	Međufunkcionalni dijagram toka za depozitno skladište[5][6].....	16
Slika 13.	Istovar robe	17
Slika 14.	Prijemna zona	18
Slika 15.	Prikaz dijela podataka tablice istovara robe	19
Slika 16.	Kretanje broja paletnih mjesta i trajanja procesa istovara.....	20
Slika 17.	Histogram trajanja procesa istovara	21
Slika 18.	Izračun statističkih pokazatelja u programu „Microsoft excel“	22
Slika 19.	Izračun broja podataka koji se nalaze unutar standardne devijacije	22
Slika 20.	Dijagram rasipanja za broj paletnih mjesta i trajanje procesa istovara	23
Slika 21.	Grafički prikaz modela linearne regresije za istovar robe	24
Slika 22.	„Box and whisker“ dijagram[11]	30
Slika 23.	„Box and whisker“ dijagram za trajanje procesa istovara i broj paletnih mjesta ..	30
Slika 24.	Dijagram odstupanja (outliers)	31
Slika 25.	Dijagram odstupanja (outliers)	31
Slika 26.	Statistička analiza trajanja procesa istovara i broja paletnih mjesta	32
Slika 27.	Prikaz mjera nagnutosti i ispučenosti normalne distribucije.....	33
Slika 28.	Dijagram modela linearne regresije	34
Slika 29.	Statistički pokazatelji modela linearne regresije	34
Slika 30.	Dijagram odstupanja (residuala)	35
Slika 31.	Prikaz podataka sa najvećim odstupanjima od modela	36
Slika 32.	Nova jednadžba modela linearne regresije.....	36
Slika 33.	Statistički pokazatelji nove jednadžbe modela linearne regresije	37
Slika 34.	Histogram trajanja procesa istovara	38
Slika 35.	Shapiro-Wilk test.....	38
Slika 36.	Kolmogorov-Smirnov test	38
Slika 37.	Prikaz odstupanja (residuala) modela linearne regresije[13]	39
Slika 38.	Analiza varijance preko „Lack of fit“ testa	41
Slika 39.	Formula za izračun parametra F (12)	41
Slika 40.	Tablica preuzimanja robe	43
Slika 41.	Pivot tablica koja povezuje snimane podatke sa značajkama na otpremnici	45
Slika 42.	Primjer „full pick“ palete	46
Slika 43.	Usporedba izmjerenih broja paletnih mjesta i dobivenih modelom.....	53
Slika 44.	Testiranje nul hipoteze o jednakosti aritmetičkih sredina	54

Slika 45.	Kvantil - Kvantil dijagram	54
Slika 46.	Analiza trajanje procesa preuzimanja.....	55
Slika 47.	Histogram trajanja procesa preuzimanja	56
Slika 48.	„Box and whisker“ dijagram za trajanje procesa preuzimanja.....	56
Slika 49.	Histogram broja različitih artikala	57
Slika 50.	Analiza broja različitih artikala	58
Slika 51.	Histogram broja paletnih mjesta.....	58
Slika 52.	Analiza broja paletnih mjesta	59
Slika 53.	Histogram broja labela	59
Slika 54.	Analiza broja labela.....	60
Slika 55.	„Box and whisker“ dijagram za tri parametra	60
Slika 56.	Dijagram raspršenosti trajanja procesa preuzimanja i broja različitih artikala	61
Slika 57.	Dijagram raspršenosti trajanja procesa preuzimanja i broja paletnih mjesta	61
Slika 58.	Dijagram raspršenosti trajanja procesa preuzimanja i broja labela	62
Slika 59.	Podaci za modeliranje	64
Slika 60.	Unos varijabli za izradu modela predviđanja	65
Slika 61.	Analiza varijabli	65
Slika 62.	Dobiveni model predviđanja i statistički pokazatelji	66
Slika 63.	Matrica korelacija.....	67
Slika 64.	Najveća studentizirana odstupanja (residuali).....	67
Slika 65.	Dijagram odstupanja (residuala)	68
Slika 66.	Izmjerena trajanja preuzimanja i trajanja predviđena modelom	68
Slika 67.	Anova test za ulazne varijable	71
Slika 68.	Procesi sa najvećim utjecajem na vrijeme.....	72

POPIS TABLICA

Tablica 1. Trajanje procesa istovara za iste dobavljače	26
Tablica 2. Odstupanje specifičnih dobavljača od prosjeka za trajanje procesa istovara	27
Tablica 3. Vremena trajanja istovara po modelu za istog dobavljača	27
Tablica 4. Usporedba izmjerenog trajanja istovara i dobivenog modelom	40
Tablica 5. Izmjereni podaci za jednu narudžbu.....	46
Tablica 6. Značajke robe za jednu narudžbu	47
Tablica 7. Izmjereni podaci za jednu narudžbu.....	49
Tablica 8. Značajke robe za jednu narudžbu	50
Tablica 9. Izračun popunjenosti paletnih mjesta za jednu narudžbu (16).....	50
Tablica 10. Usporedba izmjerenih broja paletnih mjesta i dobivenih modelom.....	51
Tablica 11. Najduža vremena preuzimanja i njihovi parametri	57
Tablica 12. Usporedba izmjerenog trajanja preuzimanja i dobivenog modelom.....	69

POPIS OZNAKA

Oznaka	Jedinica	Opis
\bar{x}		Aritmetička sredina uzorka
s		Standardna devijacija uzorka
σ^2		Varijanca uzorka
n		Veličina uzorka
X		Broj paletnih mjesta
e_i		Pogreška slučajne varijable
R^2		Koeficijent determinacije
Y	minute	Trajanje procesa
H_0		Nulta hipoteza
H_1		Alternativna hipoteza
μ_0		Očekivana srednja vrijednost
μ		Testirana srednja vrijednost
α		Razina značajnosti
z		Vrijednost test statistike (z test)
CVar		Koeficijent varijacije
d		Vrijednost Durbin-Watson testa
P		Razina signifikantnosti
SS _{ukupno}		Ukupna varijabilnost
SS _{residual}		Varijabilnost odstupanja (residuala)
SS _{regresija}		Varijabilnost objašnjena regresijskim modelom
F		Parametar „lack of fit“ testa
df		Stupnjevi slobode
KU_MP	komadi	Količina artikala koja stane u jednu kutiju
PL_MP	komadi	Količina artikala koja stane na jednu paletu
KU_ZAP		Zaprimljen broj kutija
PL_ZAP		Zaprimljeni broj paleta
SSCC/stavke		Broj potrebnih labela za jednu narudžbu
a	komadi	Naručena količina jedne vrste artikla po narudžbi
b	komadi	Količina jedne vrste artikla koja stane na jednu paletu
Z		Broj različitih artikala
Y _{istovar}	minute	Trajanje procesa istovara
Y _{preuzimanje}	minute	Trajanje procesa preuzimanja
c	minute	Vremenska konstanta za određene aktivnosti unutar skladišta
i		Broj narudžbi za jedan dan

SAŽETAK

U ovom radu opisana je uloga logističko distributivnog centra, te su na konkretnom primjeru opisani procesi istovara i zaprimanja robe u sustav skladišta distributivnog centra. Odrađeno je mapiranje procesa depozitnog skladišta Logističko-distributivnog centra poslovnog sustava „Konzum“ te je dan prikaz aktivnosti koje najviše utječu na vrijeme trajanja istovara i zaprimanja robe. Izmjerena su vremena trajanja procesa istovara i preuzimanja te je napravljena sustavna analiza značajki narudžbi robe koja ulazi u sustav u određenom vremenskom razdoblju. Cilj prikupljanja podataka i analize značajki narudžbe je dobivanje modela za predviđanje vremena trajanja procesa unutar depozitnog skladišta. Pomoću statističkih alata dobiveni su modeli linearne regresije za koje postoji signifikantna veza između ulaznih varijabli i vremena trajanja procesa.

Ključne riječi: logističko distributivni centar, mapiranje procesa, značajke narudžbe, linearna regresija.

SUMMARY

This paper describes the role of a logistics distribution center, using a specific example in which the processes of unloading and take up are described within the logistic distribution center of a warehouse system. A process mapping for the warehouse of Logistics and Distribution Center of the company "Konzum" was created, giving an overview of the activities that most influenced the duration of the unloading and take up. The duration of the unloading and take up process was measured and a systematic analysis of ordering features of goods entering the system over a specific period of time was made. The purpose of data collecting and analysis of order features is to obtain a model for predicting the time duration of the process within the warehouse. Using statistical tools, linear regression models have been obtained for which there is a significant link between the input variables and the time duration of the process.

Key words: logistics distribution center, process mapping, order features, linear regression

1. UVOD

Logistika obuhvaća sve djelatnosti potrebne za kompleksnu pripremu i realizaciju prostorne i vremenske transformacije dobara i znanja. Nastoji uporabom ljudskih resursa i sredstava u sustavima staviti na raspolaganje tržištu tražena dobra u pravo vrijeme i na pravom mjestu u traženoj količini, kvaliteti i cijeni s točnim informacijama vezanim uz ta dobra. Naglasak je na minimalnim troškovima i optimizaciji kako bi se postigla veća profitabilnost. Polazište svih aktivnosti je logističko-distributivni centar, stoga njegova efikasnost je ključna kako bi se ostvarila konkurentska prednost.[1]

Logističko-distributivni centar „Konzum“ prvenstveno ima zadaću opskrbe svojih prodavaonica svježim proizvodima na dnevnoj bazi. Kako bi to radili na uspješan način bitno je kvalitetno planiranje vremena i troškova. Jedan od većih problema je predvidjeti vremena trajanja istovara i preuzimanja robe, kako se ne bi stvarala „uska grla“ unutar cijelog procesa, a u konačnici dolazilo do kašnjenja s dostavom robe prodavaonicama. To je kompleksan zadatak iz razloga jer je više faktora koji utječu na vrijeme trajanja istovara i preuzimanja robe. Konzumov logističko-distributivni centar ima više tipova skladišta. Jedan tip je depozitno skladište(ZR), njegova glavna značajka je da roba u skladištu ostaje dulji period vremena na zalihama, u njemu se nalazi roba koja se češće kupuje stoga ju je potrebno skladištiti na takav način. Drugi tip skladišta je zero stock skladište(ZC), to je skladište gdje sva roba koja stigne u njega u pravilu se do kraja dana šalje prodavaonicama, predstavlja skladište za dnevne potrebe prodavaonica i nema stvaranja zaliha. U ovom radu fokus je na depozitnom skladištu i procesima unutar njega.

Kako bi mogli predviđati vremena trajanja procesa unutar skladišta moramo razumjeti cijeli proces od njegovog početka do kraja, a u tome nam pomažu tehnike mapiranja procesa. Njihova glavna svrha je prikazati same procese vidljivima kako bi lakše razumjeli cjelokupni sustav. Pomoću njih možemo prikazati tko je zadužen i odgovaran za pojedini proces unutar cijelog sustava, također možemo prikazati koji je redoslijed procesa. Mapiranjem procesa imamo uvid u procese koji najduže vremenski traju, te potom možemo djelovati na njih kako bi povećali efikasnost cjelokupnog sustava. Razlikujemo tri tehnike mapiranja procesa: relacijske mape, međufunkcionalne dijagrame tokova i osnovne dijagrame tokova.

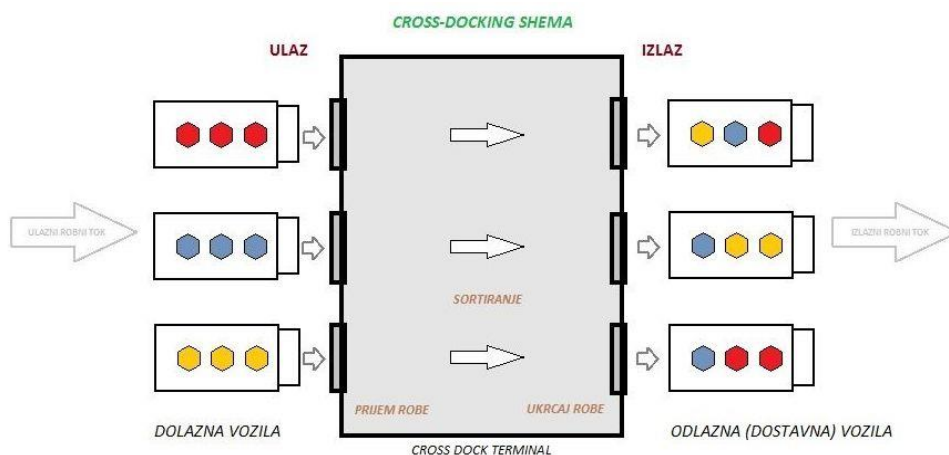
Nakon odrađenog mapiranja procesa za depozitno skladište slijedi mjerenje vremena trajanja procesa i statistička analiza izmjerenih podataka. Nakon što se ustanovi koji su procesi

najkritičniji i predstavljaju najveća „uska grla“ slijedi modeliranje dobivenih podataka. Svrha modeliranja je da se na temelju izmjerenih vremena aktivnosti istovara i preuzimanja robe te značajki narudžbe, dobije prediktivni model za izračun ukupnog vremena trajanja odlaganja robe procesa unutar depozitnog skladišta.

2. LOGISTIČKO DISTRIBUTIVNI CENTAR

Skladišta su izgrađeni objekti ili pripremljeni prostori za smještaj i čuvanje roba od trenutka njihovog preuzimanja do vremena njihove upotrebe i otpreme. To je mjesto na kojem su pohranjene zalihe te koje je uređeno i opremljeno za privremeno i sigurno odlaganje, čuvanje, pripremu i izdavanje materijala. S logističkog stajališta "skladište je čvor ili točka na logističkoj mreži na kojem se roba prije svega prihvaća ili prosljeđuje u nekom drugom smjeru unutar mreže". Glavne tehničke funkcije skladišta su skladištenje i distribucija, a cilj je prostorno i vremensko uravnoteženje tokova proizvoda. [1]

U logističko - distributivnom centru "Konzum" skladište se gotovi proizvodi, a neki od razloga skladištenja mogu biti: varijabilnost potražnje, sezonska potražnja, kratki rokovi isporuke (uvjet tržišta), otežana prodaja gotovih proizvoda, kupnja veće količine radi popusta (špekulativne zalihe). Konzumov logističko - distributivni centar ima više tipova skladišta. Jedan tip je depozitno skladište(ZR), njegova glavna značajka je da roba u skladištu ostaje dulji period vremena na zalihama, u njemu se nalazi roba koja se češće kupuje stoga ju je potrebno skladištiti na takav način. Drugi tip skladišta je zero stock skladište(ZC) ili cross docking (pretovarno skladište), to je skladište gdje sva roba koja stigne u njega u pravilu se do kraja dana šalje prodavaonicama, predstavlja skladište za dnevne potrebe prodavaonica i nema stvaranja zaliha. Cross docking podrazumijeva isporuku preko posrednika – distributera, samo što su za razliku od distribucijskog skladištenja robni tokovi ovdje neprekinuti. Cross docking se može definirati kao kontinuirani tok robe preko LDC-a, od prihvatne do otpremne funkcije, koji isključuje potrebu konvencionalnog skladištenja. Primarna uloga skladišta pritom je koordinacija ulaznih i izlaznih tokova, a ne smještaj i čuvanje robe. Glavna zadaća Cross dockinga je optimalno iskorištenje prijevoznih kapaciteta. Često se dobavljačima događa da ne popune svoje kamione, već prevoze robu polupraznim kamionima. To stvara trošak jer je prostor kamiona neiskorišten. Cilj je svakog prijevoznika popuniti vozilo što je moguće više u jednoj vožnji odnosno maksimalno iskoristiti prostor vozila. Također u LDC-u Konzum postoje skladišta za voće, povrće, meso i ostale proizvode koji moraju biti skladišteni u posebnim uvjetima (hladnjače).[2]



Slika 1. Cross - docking shema[2]

Komponente skladišnog sustava su[1]:

- Objekti/uređene površine
- Transportna sredstva
- Sredstva za odlaganje
- Sredstva za skladištenje (regali)
- Pomoćna skladišna oprema
- Dodatna skladišna oprema


Skladišni proces obuhvaća sve aktivnosti unutar i između skladišnih zona. Najčešća podjela je na prijemnu zonu, skladišnu zonu, zonu komisioniranja, zonu sortiranja i pakiranja te predajnu zonu. Tako razlikujemo 4 osnovna potprocesa u skladištu: prijem, uskladištenje, komisioniranje i izdavanje.[1]



Slika 2. Logističko distributivni centar „Konzum“ [3]


S obzirom na kriterij podjele postoje razne vrste skladišta. Za svaki od kriterija definirano je kojoj bi vrsti pripadalo Konzumovo depozitno skladište. Prva podjela je s obzirom na vrstu i značajke materijala koje se nalaze u skladištu, za slučaj depozitnog skladišta radi se o pokvarljivim proizvodima. Druga podjela je s obzirom na stupanj razvoja skladišnog sustava, depozitno skladište je djelomično automatizirano. Treća podjela je s obzirom na strategiju odlaganja materijala, depozitno skladište spada u grupu „sa slobodnim rasporedom odlaganja unutar određenog dijela skladišta“ te se roba odlaže u redovima. Četvrta podjela je s obzirom na značajke građevinskog objekta, radi se o zatvorenom, natkrivenom, prizemnom skladištu. Peta podjela je s obzirom na glavnu zamisao izvedbe objekta, razlikujemo horizontalna ili niska skladišta (visina do oko 7 metara) i okomita ili visoka (visine preko 12 metara). Depozitno skladište pripada grupi visokih skladišta. Šesta podjela je s obzirom na tehnologiju skladištenja, razlikujemo podna, regalna, visokoregalna i ona sa skladištenjem na transportnim sredstvima. Konzumovo depozitno skladište spada u visokoregalna. Sedma podjela je s obzirom na pripadnost dijelu poduzeća to jest pripadnost funkciji (nabava, prodaja, proizvodnja, kooperacije, servisa, održavanja, alatnice..) Depozitno skladište pripada funkciji nabave. Te zadnja podjela je s obzirom na vrstu sredstava za skladištenje, depozitno skladište pripada grupi sa sredstvima za skladištenje (regalna skladišta), s nepokretnim, paletnim regalima.

Uloga skladišta u logističkom lancu može biti objedinjavanje transporta. Pod pojmom objedinjavanje transporta razlikujemo konsolidaciju i pregrupiranje (razbijanje) proizvoda.



Slika 3. Konsolidacija proizvoda [1]

Razlozi za konsolidacijom transporta mogu biti: korisnik (prodavaonica) s potražnjom proizvoda od više dobavljača, količine od svakog dobavljača su manje od kapaciteta transportnih vozila i pregrupiranje robe u veće količinske jedinice (smanjenje troškova transporta).



Slika 4. Pregrupiranje proizvoda[1]


Pregrupiranje proizvoda je suprotan proces od konsolidacije, razlog pregrupiranja može biti veći broj korisnika (prodavaonica) na nekom području s potražnjom manjom od kapaciteta transportnog vozila.

2.1. Značajke „Konzum“ depozitnog skladišta

U nastavku su nabrojane značajke „Konzum“ depozitnog skladišta:

- Depozitno skladište ima svrhu zaprimiti robu od različitih dobavljača, konsolidirati ju te distribuirati prema daljnjim korisnicima, radi se o klasičnom distribucijskom skladištu.
- Roba koja se zaprima u promatranom skladištu je mješovita roba koja podrazumijeva prehranu i neprehranu. U skladište se zaprima samo roba bez posebnih uvjeta rukovanja ili skladištenja (npr. opasna roba, kemikalije, žive životinje i sl.). Sva roba u skladište dolazi na europaletama dimenzija 800 mm x 1200 mm te se nakon zaprimanja smješta na paletne regale.
- Depozitno skladište spada u grupu regalnih skladišta. Regalna skladišta su kombinacija hangarskih i etažnih skladišta. Primaju terete u nizove regala, a mogu se upotrebljavati samo za paletizirane terete ili za komade kojima se može rukovati na isti način. S obzirom na to da uski prostor između regala služi samo za unos i iznos

paleta, jedan dio skladišta nije ispunjen regalima te je namijenjen za rukovanje teretom (prihvat, kontrola, dispozicija, sortiranje, otprema itd.).



Slika 5. Prikaz regala u depozitnom skladištu

- Konzumovo depozitno skladište ima prijemne rampe na jednoj strani, a otpremne rampe na suprotnoj strani skladišta. I prijamne i otpremne rampe imaju mogućnost prilagodbe razine rampe s visinom vozila. Sve rampe su izvana natkrivene kako bi se roba i subjekti uključeni u manipulaciju robom zaštitili od vremenskih nepogoda.
- Roba se iz vozila istovara električnim niskopodnim viličarom. Robu istovaraju kontrolori ulaza na odjelu kontrole ulaza. U opremu koja se koristi prilikom prijhvata robe koriste se RF uređaji za zaprimanje robe, odnosno ručni skeneri kojima se roba unosi u skladišni sustav.



Slika 6. Električni viličar



Slika 7. Ručni RF skener

- Dobavljači ovog skladišta dovoze robu iz Hrvatske, ali i iz raznih zemalja iz Europe. Iz tog razloga i sam proces zaprimanja varira zbog različite dokumentacije za robu iz Republike Hrvatske (teretnice, dostavnice) i za robu iz ostalih zemalja (Međunarodni sporazum o prijevoznim ugovorima u cestovnom prometu robe – teretni list CMR, dostavnice, carinske isprave). Roba se većinom dovozi kamionima s poluprikolicom s rashladnom komorom ili ceradom, nosivosti do 25.000kg i kapaciteta 33 europaleta, no u nekim slučajevima, za dostavu robe unutar Hrvatske koriste se kombi vozila ili manji kamioni.


- Predviđene termine za dolazak dobavljača kreira odjel kontrole zaliha. Taj odjel kreira dokument „Yard“ na kojem se nalaze predviđena vremena za dolazak pojedinih dobavljača s fiksnim vremenima za obavljanje isporuke robe u depozitno skladište. Kontrolori ulaza rade prema tom dokumentu te oni dobavljači koji dolaze u predviđeno vrijeme imaju prednost za istovar robe. Mana ovog dokumenta je što su vremena fiksna i često loše predviđaju vrijeme potrebno za istovar i preuzimanje robe.
- Roba se iz vozila istovara električnim viličarima u prijamne zone skladišta, nakon čega se provjerava i prebrojava te se uspoređuje s količinama robe koje se nalaze na otpremnici. Robi na paletama se dodjeljuju labele na kojima su podaci o robi te skladišne lokacije koje su joj se dodijelile (sistemska zaprimanje). Na labeli se nalazi barkod i šifra. Nakon obavljenog istovara, fizičkog pregleda i sistemskog zaprimanja robe, regalnim viličarima se roba šalje na njihove skladišne lokacije.
- Depozitno skladište u svom poslovanju koristi WMS sustav. WMS sustav je računalni sustav upravljanja skladištem koji za cilj ima kontrolu kretanja i skladištenje materijala unutar skladišta. Sustav obrađuje pripadajuće transakcije, uskladištenje, popunjavanje, komisioniranje te optimizira stanje i količinu zaliha koje temelji na informacijama dobivenim u stvarnom vremenu. WMS prati napredak proizvoda kroz skladište. To uključuje fizičku infrastrukturu skladišta, sustave praćenja i komunikaciju između postaja. Jednostavnije rečeno, računalno upravljanje skladištem uključuje primitak, skladištenje i kretanje robe prema međuskladišnim mjestima ili prema krajnjem kupcu

3. MAPIRANJE PROCESA

Mapiranje procesa se koristi za vizualni prikaz poslovnih procesa s ciljem njihovog boljeg razumijevanja, kako bi jasno razlučili koje nam aktivnosti stvaraju vrijednost, a koje nam predstavljaju nepotreban trošak. Kvalitetno odrađeno mapiranje procesa unutar određenog poslovnog sustava je preduvjet za ispunjavanje poslovnih ciljeva. Prije svega da bi mogli predviđati vremena trajanja istovara robe iz kamiona moramo razumjeti cijeli proces od njegovog početka do kraja, za to nam služe tehnike mapiranja procesa. Njihova glavna svrha je prikazati same procese vidljivima kako bi lakše razumjeli cjelokupni sustav. Pomoću njih možemo prikazati tko je zadužen i odgovaran za pojedini proces unutar cijelog sustava, također možemo prikazati koji je redoslijed procesa. Mapiranjem procesa imamo uvid u procese koje nam najviše utječu na vrijeme trajanja istovara robe, te potom možemo djelovati na njih kako bi povećali efikasnost cjelokupnog sustava. Razlikujemo tri tehnike mapiranja procesa: relacijske mape, međufunkcionalne dijagrame tokova i osnovne dijagrame tokova. [4]

3.1. Relacijske mape

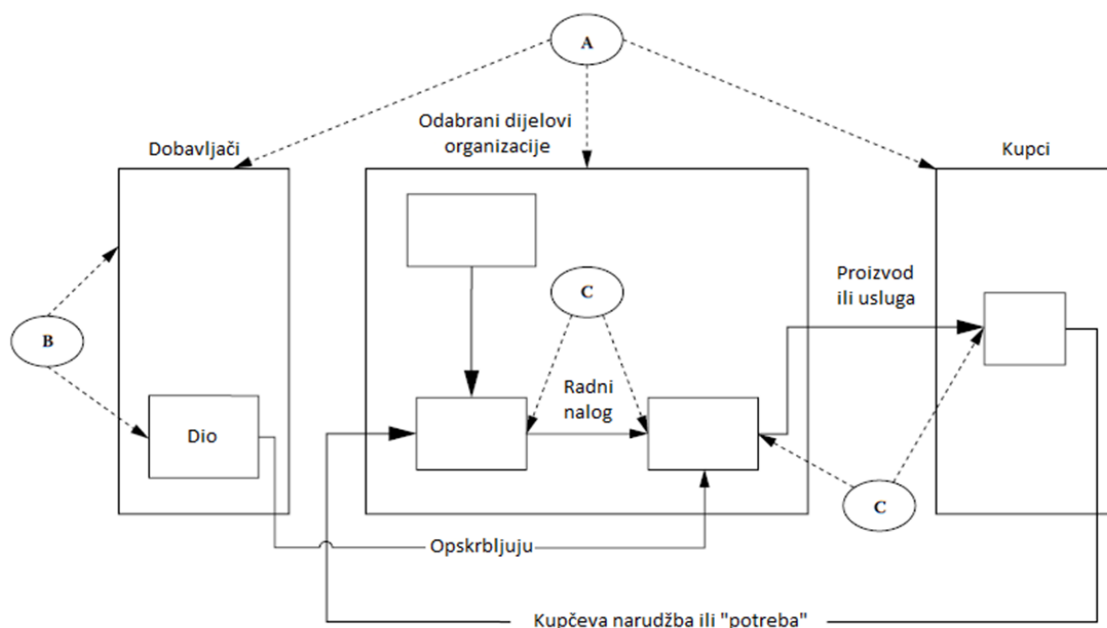
Relacijske mape vizualno opisuju "dijelove" organizacije te unutarnje ili vanjske odnose između dobavljača i kupaca među tim dijelovima. Općenito prate redoslijed s lijeva na desno (konverzija resursa ili propusnosti). Taj redoslijed predstavljaju iste tri komponente: dobavljač, organizacija i kupac; taj skup podataka predstavlja obrazac ili "predložak" za ovu vrstu mape. Relacijska mapa pomaže da se sagleda rad na razini organizacije, tako da izričito ne prikazuju radne aktivnosti. Umjesto toga, prikazuje ulazno / izlazne veze između odabranih dijelova organizacije. (Simbol pravokutnika predstavlja "dio" organizacije, taj "dio" se može zamisliti kao "kanta" resursa i aktivnosti koje postaju građevni blok organizacijske strukture, kao što su odjel, funkcija, tim, projekt itd.)[4]



Slika 8. Osnovni predložak za relacijsku mapu[4]

Razlozi zašto koristiti relacijske mape[4]:

- Prikazuju što organizacija preuzima (ulazni resursi) i ono što proizvodi (izlazi ili pretvoreni resursi) to jest njegove stavke, proizvode ili usluge.
- Prikazuju komponentu „dijelovi“ koji čine „organizacijsku cjelinu“ povezanu s određenom stavkom.
- Označavaju što svaki dio pridonosi (koji su ulazi i izlazi povezani s kojim dijelovima organizacije).
- Prikazani su vidljivima odabrani unutarnji i vanjski odnosi dobavljač-kupac.
- Ilustriraju organizacijske granice koje rad mora proći kako se stvara vrijednost.
- Osiguravaju kontekst rada; pomažu orijentirati zaposlenike, dobavljače ili druge dionike kako bi razumjeli kako se njihov rad „uklapa“ u rad organizacije.
- Označavaju dijelove i veze na koje utječe određena strategija, inicijativa ili predložena organizacijska promjena.



Slika 9. Relacijska mapa-ključne značajke: (A) dobavljač-organizacija-kupac komponente, (B) dio/cjelina odnos, (C) dobavljač-kupac odnos[4]

3.2. Međufunkcionalni dijagram toka

Međufunkcionalni dijagrami toka ilustriraju tijek rada u organizacijama. Tijek rada se sastoji od niza međusobno povezanih radnih aktivnosti i resursa koje slijede različit put, budući da se radni ulazi (resursi) pretvaraju u izlaze koji predstavljaju određenu vrijednost za korisnika. Naziv „međufunkcionalni dijagram toka“ znači da cijeli radni proces (od početka do kraja) „križa“ više funkcija ili drugih organizacijskih entiteta. Još se naziva i „swimlane diagram“, što bi u prijevodu značilo staza za plivanje. Razlog tome je što uzorak horizontalni polja dijagrama je sličan stazama olimpijskog bazena gledanog iz zraka. Dok relacijske mape prikazuju samo dijelove organizacije, međufunkcionalni dijagrami toka prikazuju rad koji se odvija unutar svakog dijela. Pravokutnici koji predstavljaju „dijelove“ organizacije na relacijskim mapama, postaju horizontalna polja u međufunkcionalnim dijagramima tokova.[4]

Glavne značajke međufunkcionalnih dijagrama toka (slika10.):

A. „Swimlane“ (horizontalno polje)

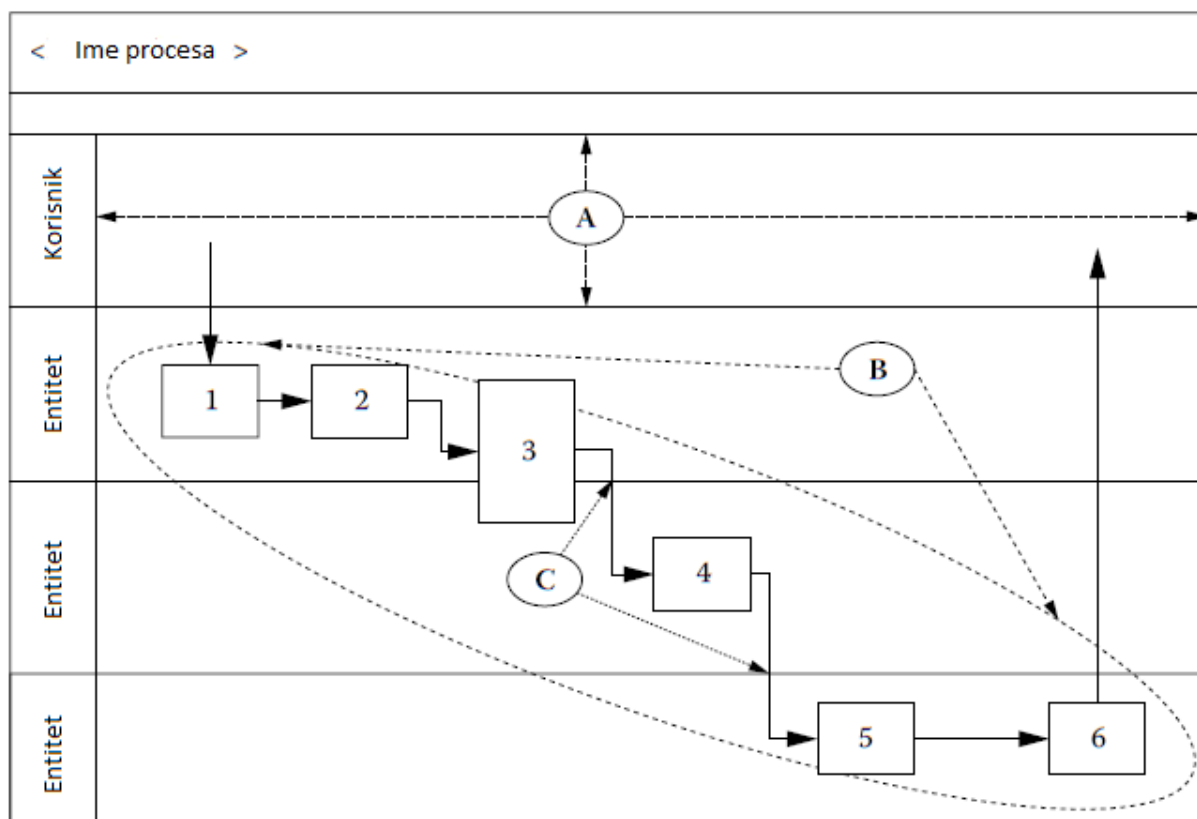
- Horizontalno polje pokazuje radne aktivnosti u kontekstu organizacijskog dijela ili drugog "entiteta" koji drži ili obavlja te aktivnosti

B. Tijek rada

- Skup međusobno povezanih aktivnosti i resursa razmještenih na jedinstven način
- Ovo je mehanizam koji stvara i donosi vrijednost

C. Odnosi između dobavljača i korisnika

- Prijenos radne aktivnosti između dva različita entiteta
- Gledano na razini sustava predstavlja vezu između dvije komponente



Slika 10. Glavne značajke međufunkcionalnog dijagrama toka[4]

Razlozi zašto koristiti međufunkcionalne dijagrame toka[4]:

- Prikazuju granice (početak i kraj) i cjelokupni tijek rada na prvi pogled.
- Ističu korisnikove točke dodira sa proizvodima ili uslugama.
- Istodobno prikazuju aktivnosti i gdje se ne organizacijskoj razini one odvijaju.
- Prikazuju odnose između dobavljača i korisnika koji su prisutni tijekom cijelog procesa.

- Ilustriraju prijelaze između entiteta (organizacijskih dijelova).
- Utvrđuju uzorke u tijeku rada (serijski, suradnički, paralelni, ili kombinacija).

3.3. Osnovni dijagram toka

Osnovni dijagrami toka predstavljaju grafički prikaz redoslijeda radnih aktivnosti koje se koriste za stvaranje, proizvodnju ili pružanje jedinstvenog izlaza (output). Može se koristiti za kategorizaciju radnih aktivnosti koje stvaraju vrijednost ili one koje ne stvaraju vrijednost. Od tri tehnike mapiranja, osnovni dijagram toka koristi se za najširi prikaz rada. [4]

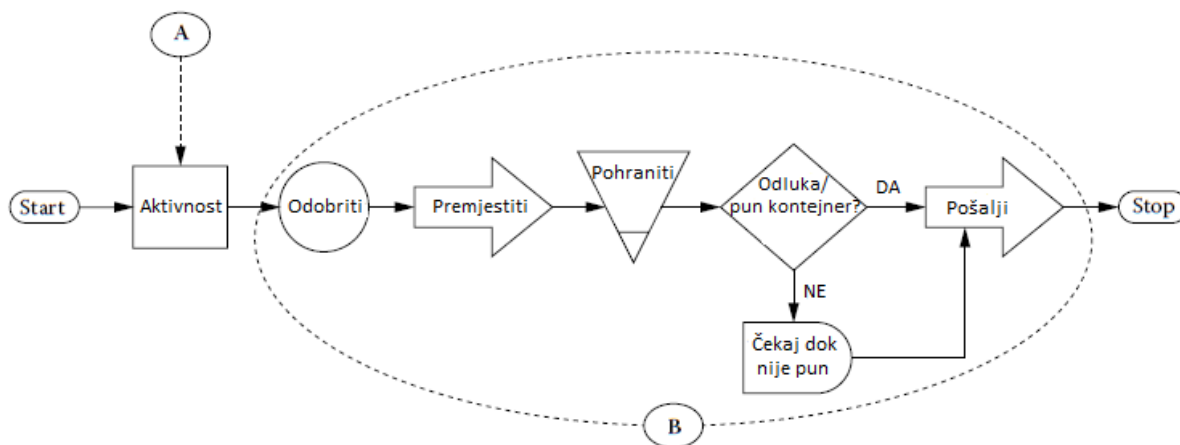
Ključne značajke dijagrama toka (slika 11.):

A. Aktivnost stvaranja vrijednosti

- Jedan simbol koristi se za predstavljanje aktivnosti koja pretvara resurse u oblik koji predstavlja vrijednost za kupca koju je on voljan platiti.

B. Aktivnost koja ne stvara vrijednost

- Skup različitih simbola koristi se za prikaz aktivnosti koje ne stvaraju vrijednosti, kao što su kašnjenja, skladištenje, pregled, odobrenje, prerada itd.
- Rad koji troši resurse i vrijeme, ali ne pretvara resurse ("kupac" smatra "otpadom")



Slika 11. Glavne značajke osnovnog dijagrama toka[4]

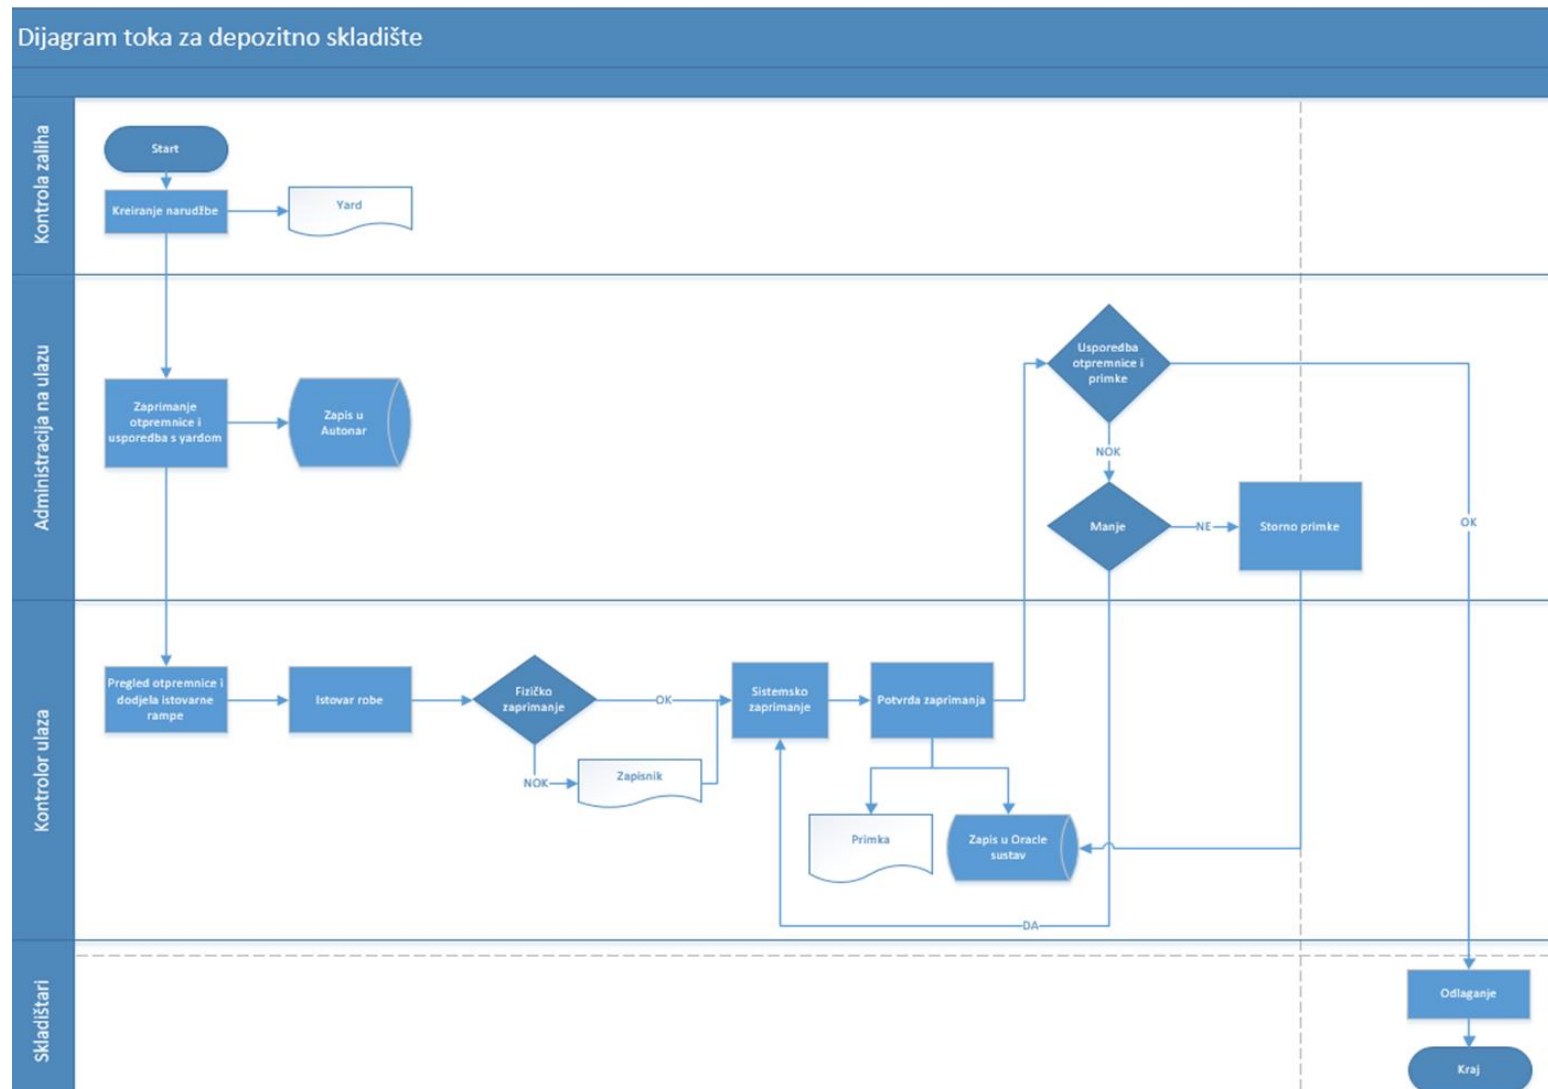
Razlozi zašto koristiti osnovni dijagram toka[4]:

- Detaljan prikaz stvarnih aktivnosti unutar nekog procesa, prikaz onoga što se događa u stvarnosti unutar poslovnih procesa.
- Razlikujemo aktivnosti stvaranja vrijednosti i aktivnosti koje ne stvaraju vrijednost.

- Možemo uočiti vidljive vrste „otpada“ u aktivnostima koje ne stvaraju vrijednost, kao što su kašnjenja, skladištenje, premještanja, pregledi, odobrenja, prerade itd.

3.4. Mapiranje procesa na primjeru „Konzum“ depozitnog skladišta

Mapiranje procesa za depozitno skladište je prikazano preko međufunkcionalnog dijagrama toka gdje se vidi tko je zadužen za koje aktivnosti unutar organizacije, u ovom slučaju „Konzum“. Tako unutar cijelog procesa razlikujemo 4 entiteta: kontrola zaliha, administracija na ulazu, kontrolori ulaza, skladištari. Sve aktivnosti kreću od kontrole zaliha koja kreira narudžbu robe za dobavljače, rezultat toga je dokument „yard“. Taj dokument se dostavlja administraciji na ulazu, a na njemu se nalazi dnevni raspored dolazaka dobavljača, te vrsta i količina robe koja dolazi. Administracija na ulazu zaprima otpremnicu od vozača kamiona i uspoređuje s „yardom“, te na otpremnicu zapisuje broj mobitela i vrijeme dolaska vozača kako bi se znalo jeli vozač došao u dogovoreno vrijeme i koliko je čekao na istovar robe. Potvrda dolaska robe od dobavljača se pohranjuje unutar „autonara“ koji predstavlja jedan dio informacijskog sustava. Zatim se otpremnica šalje kontroloru ulaza koji pregledava otpremnicu i dodjeljuje prikladnu istovarnu rampu, poziva vozača kamiona na istovarnu rampu te slijedi istovar robe. Nakon istovara slijedi fizičko zaprimanje gdje kontrolor ulaza pregledava stanje robe, količinu i rokove trajanja. Ako je roba oštećena ili pred istekom roka trajanja, kontrolor ulaza piše zapisnik kojeg daje vozaču kamiona te postoji mogućnost da ju odbije zaprimiti. Ako je s robom sve u redu, kontrolor ulaza obavlja sistemsko zaprimanje pomoću skenera. Unosom potvrde zaprimanja na skeneru vrši se zapis u WMS sustav (informacijski sustav „Oracle“) i printa se dokument „primka“. Potom se primka vraća administraciji na ulazu, koja uspoređuje količine robe na primki i otpremnici, ako se ne poklapaju slijede dvije opcije povratak na sistemsko zaprimanje ili storniranje primke te zapis u „Oracle“ sustav. Ako je sve u redu skladištar odlaže robu na regalno mjesto te završava proces zaprimanja robe.




Slika 12. Medufunkcionalni dijagram toka za depozitno skladište[5][6]

4. ISTOVAR I PREUZIMANJE ROBE


Mapiranjem procesa i uvidom u aktivnosti unutar depozitnog skladišta ustanovljeno je da procesi istovara i preuzimanja robe znatno utječu na ukupno vrijeme svih aktivnosti unutar skladišta. Određeni procesi poput poziva vozača i dodjele istovarne rampe, te čekanje dolaska vozača na istovarnu rampu možemo smatrati fiksnim vremenima. Trajanje tih vremena je otprilike jednako za svaku narudžbu, stoga fiksna vremena tih procesa će predstavljati aritmetičku sredina za više slučajeva. Dok vremena istovara i preuzimanja robe su varijabilna s obzirom na značajke narudžbe. To predstavlja problem prilikom planiranja dolazaka dobavljača, cilj je spriječiti čekanja i stvaranja “uskih grla” ostalim procesima. Stoga je izmjereno trajanje procesa istovara i preuzimanja robe za 51 slučaj kako bi se pokušalo doći do određenih saznanja o utjecaju značajki narudžbe o trajanju procesa. Na temelju tih saznanja predviđati će se trajanje procesa istovara i preuzimanja robe.

4.1. Trajanje procesa istovara u depozitnom skladištu

Sam proces istovara robe podrazumijeva da kontrolor ulaza prebaci robu iz dostavnog vozila na prijemnu zonu. Roba se u dostavnom vozilu nalazi na paletama, a kontrolor ulaza pomoću viličara obavlja proces istovara. Trajanje toga procesa je direktno vezano uz broj paletnih mjesta u dostavnom vozilu jer njihov broj utječe na broj ulazaka kontrolora u dostavno vozilo. Slike prikazuju sami proces istovara robe i prijemnu zonu gdje se roba odlaže kako bi se obavili slijedeći procesi.



Slika 13. Istovar robe



Slika 14. Prijemna zona

Podaci koji su prikupljivani prilikom mjerenja trajanja procesa istovara robe:


- broj otpremnice,
- dobavljač,
- datum dolaska dobavljača,
- vrijeme početka procesa,
- vrijeme kraja procesa,
- trajanje procesa u minutama,
- broj paletnih mjesta u dostavnom vozilu.

Tablica istovara robe						
Dobavljač	Broj otpremnice	Broj paletnih mjesta	Datum	Vrijeme početka procesa	Vrijeme kraja procesa	Trajanje procesa (minute)
Dobavljač 1	419400	26	10/4/2018	10:07	10:17	10
Dobavljač 2	2018-RTL-000152	4	10/4/2018	10:57	10:59	2
Dobavljač 3	87/1/1	1	10/4/2018	11:14	11:15	1
Dobavljač 4	2018-104-002725 ; 2018-182-000007	4	10/4/2018	11:27	11:30	3
Dobavljač 5	96	16	10/4/2018	12:01	12:10	9
Dobavljač 6	8/18	1	10/4/2018	12:43	12:44	1
Dobavljač 7	3623	33	10/4/2018	12:57	13:11	14
Dobavljač 8	DA18013230	33	10/5/2018	9:44	9:58	14
Dobavljač 9	30521-07002229-18	7	10/5/2018	10:18	10:22	4
Dobavljač 10	18448	28	10/5/2018	10:41	10:53	12
Dobavljač 11	40486	3	10/5/2018	11:24	11:26	2
Dobavljač 12	10-2018-2770	3	10/5/2018	12:40	12:42	2
Dobavljač 13	771	3	10/5/2018	13:01	13:05	4
Dobavljač 14	50541-07000857-18	2	10/10/2018	9:18	9:19	1
Dobavljač 15	80011160	3	10/10/2018	9:28	9:30	2
Dobavljač 16	IK0802957	5	10/10/2018	9:49	9:54	5
Dobavljač 17	20427339	1	10/10/2018	10:34	10:35	1
Dobavljač 18	682-4/2018 ; 682/2018	6	10/10/2018	10:50	10:52	2
Dobavljač 19	1047/18 ; 1046/18	32	10/10/2018	11:15	11:27	12
Dobavljač 20	PRO18015790	33	10/10/2018	11:55	12:07	12
Dobavljač 21	149/18	31	10/10/2018	12:54	13:06	12
Dobavljač 22	2018-ZG-167273-OTP	15	10/10/2018	12:44	12:51	7
Dobavljač 23	961-212	24	10/11/2018	15:32	15:46	14
Dobavljač 24	5030-ISK-300	33	10/11/2018	16:43	17:02	19
Dobavljač 25	190258-183-190	3	10/11/2018	15:17	15:20	3
Dobavljač 26	6266847803	33	10/11/2018	15:58	16:21	23
Dobavljač 27	PRO18015940	32	10/12/2018	9:10	9:24	14
Dobavljač 28	1729 ; 6081	10	10/12/2018	10:23	10:32	9
Dobavljač 29	10-2018-2819	4	10/12/2018	11:19	11:23	4
Dobavljač 30	2018-ZG-167350-OTP	9	10/12/2018	11:45	11:49	4
Dobavljač 31	A30043138	3	10/12/2018	12:15	12:19	4
Dobavljač 32	222	7	10/12/2018	12:22	12:27	5
Dobavljač 33	9002536264 ; 9002531748	26	10/12/2018	12:46	12:57	11
Dobavljač 34	PRO18015915	1	10/12/2018	9:16	9:17	1
Dobavljač 35	9002531033	32	10/12/2018	10:06	10:22	16
Dobavljač 36	87	30	10/12/2018	11:59	12:09	10
Dobavljač 37	20002318	1	10/12/2018	12:32	12:33	1
Dobavljač 38	82234528 ; 82237206	24	10/12/2018	12:49	12:59	10
Dobavljač 39	70-891076	3	10/15/2018	9:14	9:16	2
Dobavljač 40	61/2018	6	10/15/2018	10:05	10:07	2
Dobavljač 41	OT-2018-12733	24	10/15/2018	10:27	10:37	10
Dobavljač 42	2.536 ; 2.535	23	10/15/2018	11:08	11:24	16
Dobavljač 43	695/2018	11	10/15/2018	12:03	12:07	4
Dobavljač 44	OTK18-F-04925	3	10/15/2018	9:40	9:44	4
Dobavljač 45	4100014592	5	10/15/2018	10:13	10:17	4
Dobavljač 46	80196401	34	10/15/2018	10:25	10:46	21
Dobavljač 47	2018-ZG-167446-OTP	16	10/16/2018	10:46	10:56	10
Dobavljač 48	180R0002084	12	10/16/2018	11:32	11:40	8
Dobavljač 49	2469	4	10/16/2018	11:30	11:32	2
Dobavljač 50	2100407237	28	10/16/2018	11:00	11:09	9
Dobavljač 51	10001-734-6305-18	12	10/16/2018	11:50	11:55	5

Slika 15. Prikaz dijela podataka tablice istovara robe

4.2. Analiza prikupljenih podataka o trajanju procesa istovara

Nakon prikupljanja podataka za trajanje procesa istovara robe napravljena je statistička analiza podataka. Analiza podataka napravljena je u programu „Microsoft excel“. Prikupljen je 51 slučaj te je napravljena usporedba kako se kreću trajanje procesa istovara i broj paletnih mjesta.



Slika 16. Kretanje broja paletnih mjesta i trajanja procesa istovara

Iz slike je jasno vidljivo da broj paletnih mjesta utječe na vrijeme trajanje procesa istovara, jer svaki zabilježeni skok broj paletnih mjesta u dijagramu je popraćen skokom trajanja procesa istovara. Postoje i određena odstupanja u dijagramu, koja su vjerojatno vezana uz određene ljudske faktore jer je teško simulirati potpuno idealne radne uvjete.

Kada postoji mnogo podataka, koriste se vrijednosti koje opisuju te podatke. Tako, najveća i najmanja vrijednost govore o rasponu podataka koje imamo, no vrlo često ekstremi nam nisu bitni. Važnija je vrijednost kojoj je većina podataka bliska. Iz brojnih razloga danas se najčešće koristi aritmetička sredina i standardna devijacija. Aritmetička sredina ili srednja vrijednost predstavlja sumu svih podataka podijeljenu s ukupnim brojem podataka. Za brojevni niz podataka x_1, \dots, x_n njihovom aritmetičkom sredinom (srednjom vrijednosti) zovemo broj[7] (1):

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (1)$$


Za brojevni niz podataka x_1, \dots, x_n standardna devijacija predstavlja prosječno odstupanje od srednje vrijednosti i iznosi [7](2):

$$s = \sqrt{\frac{(\bar{x} - x_1)^2 + (\bar{x} - x_2)^2 + \dots + (\bar{x} - x_n)^2}{n}} \quad (2)$$

Aritmetička sredina daje broj koji se često u teorijskom i praktičnom pogledu smatra najbližim podacima. S druge strane, standardna devijacija kaže kolika je ta bliskost. Što je standardna devijacija manja, to je x bliži podacima. Ako je $s = 0$, sve vrijednosti su iste, a x je jednak svim vrijednostima.

Varijanca (znak σ^2) predstavlja mjeru disperzije mjerenih ili slučajnih veličina; prosječna suma kvadrata odstupanja vrijednosti obilježja (veličine) od aritmetičke sredine. Za niz vrijednosti x_1, x_2, \dots, x_n , varijanca je suma kvadrata odstupanja svih podataka od njihove srednje vrijednosti podijeljene s N gdje N predstavlja ukupan broj podataka u uzorku [7] (3):

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (3)$$



Slika 17. Histogram trajanja procesa istovara

Iz grafikona raspodjele trajanja procesa istovara vidljivo je da istovar u najviše slučajeva traje 2 ili 4 minute, to vrijedi za ukupno 16 slučajeva.

Trajanje procesa (minute)	aritmetička sredina	standardna devijacija	varijanca	min	max
10	7.392156863	5.748316036	33.043137	1	23
2					
1					
3					
9					
1					
14					
14					
4					
12					
2					
2					
4					
1					
2					
5					

Slika 18. Izračun statističkih pokazatelja u programu „Microsoft excel“


U programu „Microsoft excel“ izračunati su statistički pokazatelji trajanja procesa istovara. U prosjeku proces istovara robe traje 7,39 minuta sa standardnom devijacijom od 5,75 minuta. Varijanca iznosi 33,04 , a minimalno trajanje procesa istovara je 1 minuta, dok najduže zabilježeno trajanje procesa istovara je 23 minute. Standardna devijacija predstavlja broj koji govori u kojem rasponu možemo očekivati da će se kretati trajanje procesa istovara robe. Da bi to prikazali izračunato je koji broj slučajeva trajanja procesa istovara se nalazi na brojevnom pravcu udaljen od aritmetičke sredine do standardne devijacije, to jest u intervalu $[\bar{x} - s, \bar{x} + s]$.

=COUNTIFS(A2:A52,">1.64",A2:A52,"<13.14")						
A	B	C	D	E	F	
Trajanje procesa (minute)	aritmetička sredina	standardna devijacija	varijanca	min	max	
10	7.392156863	5.748316036	33.0431373	1	23	
2						
1	ukupan broj podataka	51				
3	$\bar{x} - s$	1.643840826				
9	$\bar{x} + s$	13.1404729				
1	broj podataka	36				
14	postotak	70.59%				
14						
4						

Slika 19. Izračun broja podataka koji se nalaze unutar standardne devijacije

Rezultati su pokazali da 36 podataka ili 70,59% podataka se nalazi u intervalu jedne standardne devijacije. Dok u intervalu dvije standardne devijacije $[\bar{x} - 2s, \bar{x} + 2s]$ se nalazi 48 podataka ili 94,12% podataka dok u intervalu od tri standardne devijacije $[\bar{x} - 3s, \bar{x} + 3s]$ se nalazi 100% podataka.

Nakon izračunatih statističkih pokazatelja za vrijeme trajanja procesa istovara, napravljena je usporedba vremena trajanja procesa istovara s brojem paletnih mjesta. U nastavku je prikazan dijagram ovisnosti te dvije varijable to jest dijagram rasipanja.




Slika 20. Dijagram rasipanja za broj paletnih mjesta i trajanje procesa istovara

Dijagram rasipanja ili ovisnosti broja paletnih mjesta i trajanja procesa istovara robe prikazuje koordinatni sustav gdje se na osi apscisi nalazi trajanje procesa istovara robe, a na osi ordinati broj paletnih mjesta. Svaka točka unutar dijagrama je vezana za pripadajući broj paletnih mjesta i trajanje procesa istovara. Iscrtkana linija opisuje točke unutar dijagrama te se vidi jasan trend rasta tih točaka. One točke koje se u dijagramu najudaljenije od iscrtkane linije predstavljaju najveća odstupanja od prosjeka. Iz ovog dijagrama možemo zaključiti da je odnos trajanja procesa istovara i broja paletnih mjesta donekle linearan. Kao što je već izračunato prosječno trajanje procesa istovara iznosi 7,39 minute, a prosječan broj paletnih mjesta je 14,57.

4.3. Izrada modela predviđanja trajanja procesa istovara

Linearna regresija predstavlja linearnu zavisnost jedne varijable (y) o jednoj nezavisnoj varijabli (x), u ovom slučaju broj paletnih mjesta je nezavisna varijabla (x), a trajanje procesa istovara zavisna varijabla (y). Nezavisna varijabla je varijabla čiju vrijednost određuje osoba koja provodi pokus, a zavisna varijabla je varijabla čije vrijednosti ovise o vrijednosti nezavisne varijable. Pretpostavka je da postoji funkcija $f(x)$ takva da se za svaku vrijednost nezavisne varijable x_i , zavisna varijabla može napisati kao: $y_i = f(x_i) + e_i$ gdje je pogreška e_i slučajna varijabla s normalnom raspodjelom i očekivanom vrijednošću nula. Pretpostavka je da postoje koeficijenti a i b takvi da se za svaku vrijednost nezavisne varijable x_i , ovisna varijabla može napisati kao: $y_i = bx_i + a + e_i$. Koeficijenti a i b najčešće se određuju metodom najmanjih kvadrata koja minimizira vrijednosti kvadrata udaljenosti između opaženih podataka i regresijske krivulje (pravca).[8]

Pomoću programa „Microsoft excel“ određena je jednadžba modela linearne regresije koja pokazuje ovisnost broja paletnih mjesta o trajanju procesa istovara robe, podaci su prikazani grafički i dijagramom rasipanja te je izračunata reprezentativnost modela.



Slika 21. Grafički prikaz modela linearne regresije za istovar robe

Jednadžba koja opisuje model linearne regresije glasi (4):

$$y = 0,4287 x + 1,1471 \quad (4)$$

s obzirom da opći oblik jednadžbe glasi $y = bx + a$, slijedi da parametri iznose:

- $a = 1,1471$
- $b = 0,4287$

Kada bi broj paletnih mjesta (x) iznosio nula, slijedi da bi trajanje procesa istovara (y) bilo jednako parametru a :

$$y = 0,4287 * 0 + 1,1471 = 1,1471$$

To bi značilo da kada imamo 0 paletnih mjesta, vrijeme trajanja procesa istovara iznosi 1,1471 minuta, što u stvarnosti nije tako. Ovaj model daje očekivana kretanja trajanja procesa s obzirom na broj paletnih mjesta s određenom reprezentativnosti. R^2 predstavlja koeficijent determinacije, taj podatak nam govori koliko je model reprezentativan. U našem slučaju reprezentativnost modela ili koeficijent determinacije iznosi 84,29%, u praksi ako je koeficijent determinacije veći od 80% model je reprezentativan. To znači da 84,29% veze između broja paletnih mjesta i trajanja procesa istovara je objašnjeno linearnim regresijskim modelom.

Koeficijent determinacije se često koristi kao pokazatelj adekvatnosti regresijskog modela. To je broj koji ukazuje na to uolikoj mjeri (%) ispitivana nezavisno promjenjiva veličina x utječe na zavisno promjenjivu veličinu y (5).

$$R^2 = \frac{SKO_{regresije}}{SKO_{ukupno}} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Koeficijent determinacije predstavlja odnos suma kvadrata odstupanja objašnjene regresijskom funkcijom te sveukupne sume kvadrata odstupanja. U pravilu, što je koeficijent determinacije bliži jedinici, model je reprezentativniji. Iznos koeficijenta determinacije može biti u intervalu $0 \leq R^2 \leq 1$. Što je taj koeficijent bliži 1, to znači da je manja vrijednost sume kvadrata odstupanja ostataka, pa tako i rasipanje vrijednosti oko pravca regresije.[9]

U primjeru je za 20 paletnih mjesta napravljeno predviđanje trajanja istovara, slijedi:

$$y = 0,4287 * 20 + 1,1471 = 9,72 \text{ minute}$$

Ako broj paletnih mjesta iznosi 20, može se očekivati vrijeme trajanja procesa istovara od 9,72 minute prema linearnom regresijskom modelu s reprezentativnosti od $R^2=0,8429$.

4.4. Testiranje utjecaja dobavljača na vrijeme trajanja istovara

Pomoću programa „Microsoft excel“ izračunato je za svaki slučaj potrebno vrijeme za istovar jedne palete, te je izračunat prosjek za sve slučajeve i standardna devijacija. Tim izračunom dobiveno je da prosječno vrijeme istovara jedne palete iznosi 0,65 minuta, sa standardnom devijacijom od 0,28 minuta. U nastavku su prikazani podaci za one dobavljače čija su vremena istovara izmjerena više puta, kako bi usporedili postoji li utjecaj različitih dobavljača na vrijeme istovara. Prikazani su podaci za one dobavljače koji su proces istovara obavili 3 ili više puta.

Tablica 1. Trajanje procesa istovara za iste dobavljače

Dobavljač	Broj paletnih mjesta	Datum	Vrijeme početka procesa (sati i minute)	Vrijeme kraja procesa (sati i minute)	Trajanje procesa (minute)	Vrijeme potrebno za istovar jedne palete (minute)
DOBAVLJAČ A	15	10/10/2018	12:44	12:51	7 min	0,46 min
DOBAVLJAČ A	9	12/10/2018	11:45	11:49	4 min	0,44 min
DOBAVLJAČ A	16	16/10/2018	10:46	10:56	10 min	0,62 min
DOBAVLJAČ B	33	10/10/2018	11:55	12:07	12 min	0,36 min
DOBAVLJAČ B	32	12/10/2018	9:10	9:24	14 min	0,44 min
DOBAVLJAČ B	1	12/10/2018	9:16	9:17	1 min	1 min

Tablica 2. Odstupanje specifičnih dobavljača od prosjeka za trajanje procesa istovara

Dobavljač	Prosječan broj paletnih mjesta	Prosječno vrijeme trajanja istovara (minute)	Izračun aritmetičke sredine vremena potrebnog za istovar jedne palete (minute)	Odstupanje od prosjeka svih slučajeva (0,65minuta)
DOBAVLJAČ A	13,33	7 min	0,52 min	20 %
DOBAVLJAČ B	22	9 min	0,6 min	7,7 %

Nakon napravljene analize za slučajeve istovara robe istih dobavljača, najveće odstupanje od prosjeka za istovar jedne palete iznosi 0,13 minuta (20%). Prosječan broj paleta za tog dobavljača je 13,33 dok je vrijeme istovara 7 minuta. Za tog dobavljača pomoću jednadžbe modela linearne regresije izračunato je očekivano trajanje procesa istovara

Tablica 3. Vremena trajanja istovara po modelu za istog dobavljača

Dobavljač	Broj paletnih mjesta (x)	Izmjereno trajanje procesa	Model linearne regresije ($y=0,4287x+1,1471$)	Odstupanje izmjerenog od modela
DOBAVLJAČ A	15	7 min	7,58 min	7,7 %
DOBAVLJAČ A	9	4 min	5 min	20 %
DOBAVLJAČ A	16	10 min	8 min	20 %

Na temelju n mjerenja slučajne varijable X , odnosno na temelju vrijednosti (x_1, \dots, x_n) slučajnog uzorka (X_1, \dots, X_n) , donosimo odluku o prihvatanju (DA) ili odbacivanju (NE) određene pretpostavke o svojstvima slučajne varijable X . Takva pretpostavka zove se statistička hipoteza, a postupak donošenja odluke o prihvatanju ili odbacivanju statističke hipoteze zove se testiranje. U ovom slučaju testirati ćemo hipotezu utjecaja određenog tipa dobavljača na trajanje procesa istovara robe.[10]

- $X \sim N(\mu, \sigma^2)$, σ poznata, za slučaj trajanja procesa istovara
- imamo slučajni uzorak veličine $n=3$: (X_1, \dots, X_3)

- želimo testirati da li je očekivanje μ jednako nekom unaprijed zadanom broju μ_0 .
Nulta hipoteza je $H_0 : \mu = \mu_0$. Za alternativnu hipotezu možemo uzeti bilo koju od sljedeće tri: $H_1 : \mu \neq \mu_0$ ili $H_1 : \mu > \mu_0$ ili $H_1 : \mu < \mu_0$
- u sva 3 slučaja koristimo istu test-statistiku (6):

$$Z = \frac{\bar{X}_n - \mu_0}{\frac{\sigma}{\sqrt{n}}} \quad (6)$$

Ako je nulta hipoteza $H_0 : \mu = \mu_0$ istinita, tada je $E[\bar{X}] = \mu_0$, odnosno $Z \sim N(0,1)$ [10]

U nastavku je napravljeno testiranje statističke hipoteze uzorka (isti dobavljač „DOBAVLJAČ A“) sa značajem 0,05. Ukupni podaci za trajanje istovara po jednoj paleti imaju standardnu devijaciju $\sigma = 0,2784$. Pretpostavka je da su podaci normalno distribuirani.

Slijedi postavljanje hipoteza:

$$H_0 : \mu = 0,65$$

$$H_1 : \mu \neq 0,65$$

Nulta hipoteza je da je srednja vrijednost trajanja procesa istovara jedne palete 0,65 dok je alternativna hipoteza da je srednja vrijednost trajanja procesa istovara jedne palete manja ili veća od 0,65.

Računanje vrijednosti test statistike (7):

$$Z = \frac{\bar{X}_n - \mu_0}{\frac{\sigma}{\sqrt{n}}} \quad (7)$$

- $\mu_0 = 0,65$
- $\bar{X}_3 = 0,52$
- $n = 3$
- $\sigma = 0,2784$
- $\alpha = 0,05$

$$\rightarrow z = -0,8087$$

Iz statističkih tablica očitavamo: $z_{0,05} = 1,65$, $z_{0,025} = 1,96$

$$-1,96 \leq -0.8087 \leq 1,96$$

Ako je nulta hipoteza $H_0: \mu = \mu_0$ istinita, tada (8)


$$P\left(-z_{\frac{\alpha}{2}} \leq Z \leq z_{\frac{\alpha}{2}}\right) = 1 - \alpha \quad (8)$$

što je vjerojatnost da prihvatimo H_0 ako je ona istinita .


Iz toga slijedi da nultu hipotezu ne možemo odbaciti, nulta hipoteza je pretpostavka da se uzorak i ukupan skup podataka ne razlikuju u ispitivanom obilježju, tj. da su opažene razlike slučajne. Niti jedan statistički zaključak o populaciji na bazi uzorka nije stopostotno siguran, tako i prihvatanje neke hipoteze na temelju uzorka ne znači da je ta hipoteza točna. Umjesto "hipotezu prihvaćamo" ispravnije je reći "na osnovi uzorka ne postoji razlog za odbacivanje hipoteze". Prilikom donošenja odluke o istinitosti hipoteze postoje dvije vrste mogućih pogrešaka : pogreška 1. vrste: odbacili smo nultu hipotezu ako je ona istinita te pogreška 2. vrste: prihvatili smo nultu hipotezu ako je ona neistinita. Temeljem testiranja statističke hipoteze odbacujemo utjecaj vrste dobavljača na trajanje istovara robe sa značajem od 0,05.

4.5. Optimizacija parametara i modela predviđanja trajanja istovara


Optimizacija predstavlja završni korak prilikom kreiranja modela predviđanja trajanja istovara robe. Pomoću „box and whisker“ dijagrama pokušati će se naći podaci koji odstupaju od ukupnog skupa podataka (outliers). Kutijasti dijagram ili box-plot (box and whisker dijagram) je jednostavan graf koji prikazuje karakterističnu petorku. Box-plot se sastoji od pravokutnika koji prikazuje podatke od donjeg do gornjeg kvartila. Crta po pravokutniku označava medijan (srednju vrijednost). Donje i gornje horizontalne linije se nazivaju whisker (brkovi dijagrama). Mogu se različito definirati, ali najčešće predstavljaju najmanji i najveći podatak koji se nalazi unutar 1.5 puta interkvartilni raspon gledajući od donjeg, odnosno gornjeg kvartila. Sve točke izvan te granice se crtaju posebno i smatraju outlierima (vrijednosti koje odudaraju od ostalih). Izgled box-plota ukazuje na stupanj raspršenosti i asimetričnosti (skewness), te može pokazati outliere među podacima. Optimizacija modela i parametara napravljena je u programu „Statgraphics 18“.



Slika 22. „Box and whisker“ dijagram[11]




Slika 23. „Box and whisker“ dijagram za trajanje procesa istovara i broj paletnih mjesta



Slika 24. Dijagram odstupanja (outliers)

Iz dijagrama „outliera“ vidljivo je da se svi podaci nalazi unutar 3 standardne devijacije, najbliži toj granici je podatak trajanja istovara od 23 minute u redu broj 26.



Slika 25. Dijagram odstupanja (outliers)

Nakon izbacivanja tog podataka, promijenila se srednja vrijednost trajanja procesa istovara (sample mean) i standardna devijacija.

Multiple Variable Analysis (DOBRO)		
Summary Statistics		
	Trajanje procesa istovara	Broj paletnih mjesta
Count	50	50
Average	7.08	14.2
Standard deviation	5.35225	12.1487
Coeff. of variation	75.5967%	85.5545%
Minimum	1.0	1.0
Maximum	21.0	34.0
Range	20.0	33.0
Std. skewness	2.01131	1.35294
Std. kurtosis	-0.65619	-2.14058

The StatAdvisor
 This table shows summary statistics for each of the selected data variables. It includes measures of central tendency, measures of variability, and measures of shape. Of particular interest here are the standardized skewness and standardized kurtosis, which can be used to determine whether the sample comes from a normal distribution. Values of these statistics outside the range of -2 to +2 indicate significant departures from normality, which would tend to invalidate many of the statistical procedures normally applied to this data. In this case, the following variables show standardized skewness values outside the expected range:
 Trajanje procesa istovara
 The following variables show standardized kurtosis values outside the expected range:
 Broj paletnih mjesta
 To make the variables more normal, you might try a transformation such as LOG(Y), SQRT(Y), or 1/Y.

Slika 26. Statistička analiza trajanja procesa istovara i broja paletnih mjesta

Na slici se može vidjeti da za trajanje procesa istovara statistički pokazatelj iznose:

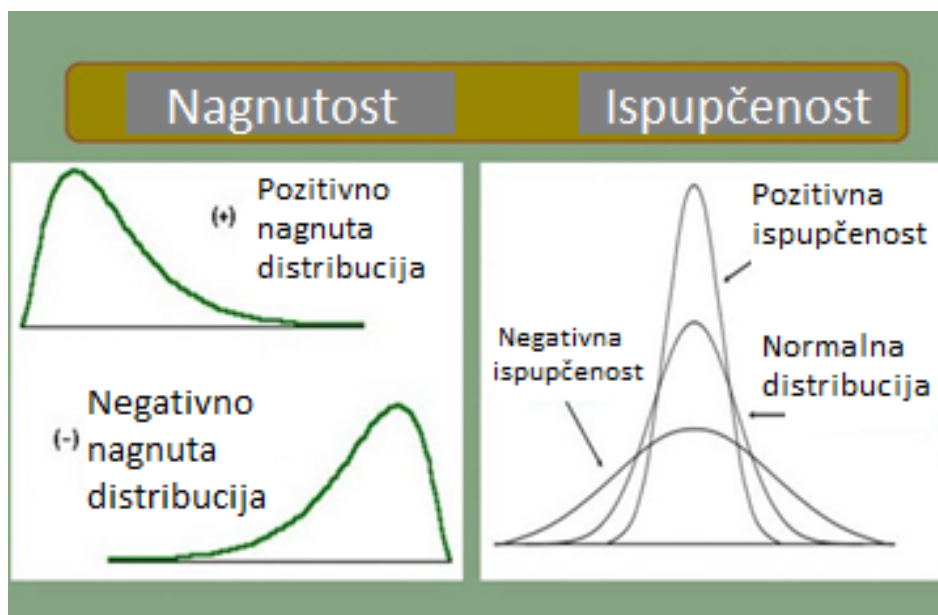
- aritmetička sredina (average) = 7,08
- standardna devijacija (standard deviation) = 5,35225
- koeficijent varijacije (coeff. of variaton) = 75,59 %
- minimum = 1
- maksimum = 21
- raspon = 20
- nagnutost normalne razdiobe (skewnes) = 2,01131
- ispučenost normalne razdiobe (kurtosis) = -0,65619

Za broj paletnih mjesta vrijedi:

- aritmetička sredina (average) = 14,2
- standardna devijacija (standard deviation) = 12,148
- koeficijent varijacije (coeff. of variaton) = 85,55 %
- minimum = 1


- maksimum = 34
- raspon = 33
- nagnutost normalne razdiobe (skewnes) = 1,35294
- ispupčenost normalne razdiobe (kurtosis) = -2,14058

Koeficijent varijacije (CVar) je omjer vrijednosti standardne devijacije uzorka sa srednjom vrijednosti podataka u uzorku. Mjere nagnutosti i ispupčenosti distribucije podataka su opisane na slici.

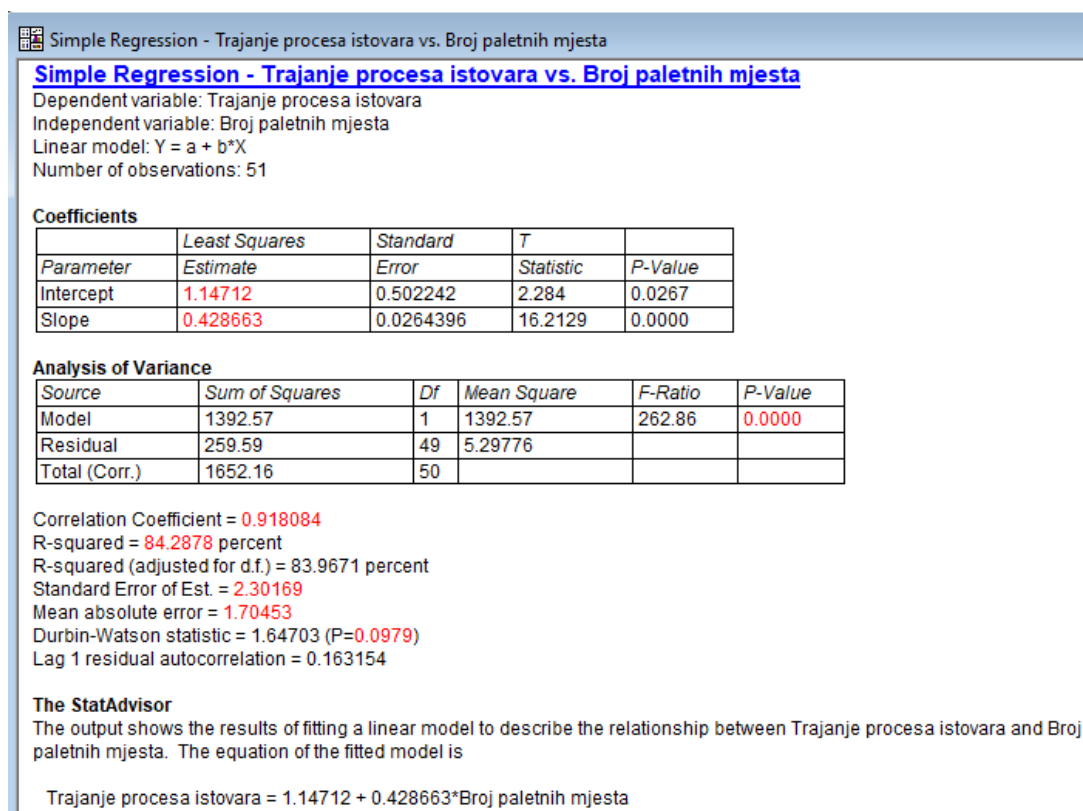


Slika 27. Prikaz mjera nagnutosti i ispupčenosti normalne distribucije

Nakon pokušaja pronalaska „outliersa“ za skup podataka, slijedi optimizacija modela gdje će se pronaći najveća odstupanja izmjerenih podataka od modela. Zavisnost trajanja procesa istovara i broja paletnih mjesta smo opisali modelom linearne regresije.



Slika 28. Dijagram modela linearne regresije



Slika 29. Statistički pokazatelji modela linearne regresije


Koeficijent korelacije izražava veličinu povezanosti među varijablama, koeficijent korelacije trajanja procesa istovara i broja paletnih mjesta iznosi 0,918. Koeficijent determinacije iznosi 0,8423. Standardna devijacija odstupanja izmjerene od modela iznosi 2,3 dok je srednja

vrijednost odstupanja 1,7. Durbin - Watson test, pokazatelj je reprezentativnosti regresijskog modela.

Regresijski modeli mogu imati različitu aplikativnu vrijednost, ovisno o kvaliteti modela. U tu svrhu koriste se različite mjere reprezentativnosti regresijskog modela. Jedan od takvih pokazatelja jest Durbin-Watsonov d-pokazatelj kojim se ispituje problem korelacije slučajne varijable (greške relacije) regresijskog modela.[12] Test veličina je (9):

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} \quad (9)$$

gdje je d oznaka test veličine Durbin-Watsonova, e_i slučajna varijabla. U standardnim knjigama iz statistike u prilogu se nalaze tablice kritičnih vrijednosti d-pokazatelja. Testiranje se provodi za dani broj opservacija (n), broj nezavisnih varijabli (K) i razinu signifikantnosti (P). Parametar d iznosi 1,647 što nam pokazuje da je P -value 0,0979 i da ne možemo tvrditi da postoji serijska autokorelacija odstupanja (residuala) modela sa razinom sigurnosti od 95%. Što je vrijednost d bliže 2 veća je vjerojatnost da ne postoji autokorelacija odstupanja (residuala).[12] Slijedi postupak izbacivanja podataka za koja imamo najveća odstupanja modela od izmjerenog, pazeći pritom da ne odbacimo preveliku količinu podataka.




Slika 30. Dijagram odstupanja (residuala)

Simple Regression - Trajanje procesa istovara vs. Broj paletnih mjesta					
Unusual Residuals					
Row	X	Y	Predicted Y	Residual	Studentized Residual
26	33.0	23.0	15.293	7.70699	3.94
42	23.0	16.0	11.0064	4.99362	2.30
46	34.0	21.0	15.7217	5.27833	2.50

The StatAdvisor
 The table of unusual residuals lists all observations which have Studentized residuals greater than 2 in absolute value. Studentized residuals measure how many standard deviations each observed value of Trajanje procesa istovara deviates from a model fitted using all of the data except that observation. In this case, there are 3 Studentized residuals greater than 2, one greater than 3. You should take a careful look at the observations greater than 3 to determine whether they are outliers which should be removed from the model and handled separately.

Slika 31. Prikaz podataka sa najvećim odstupanjima od modela

U tablici su prikazana najveća odstupanja izmjerenih podataka od modela, redove u kojima se nalaze najveća odstupanja u tablici biti će izbačeni te kreiran novi model. Izbaciti će se prikazana tri podataka što čini 5,88 % ukupnih podataka.



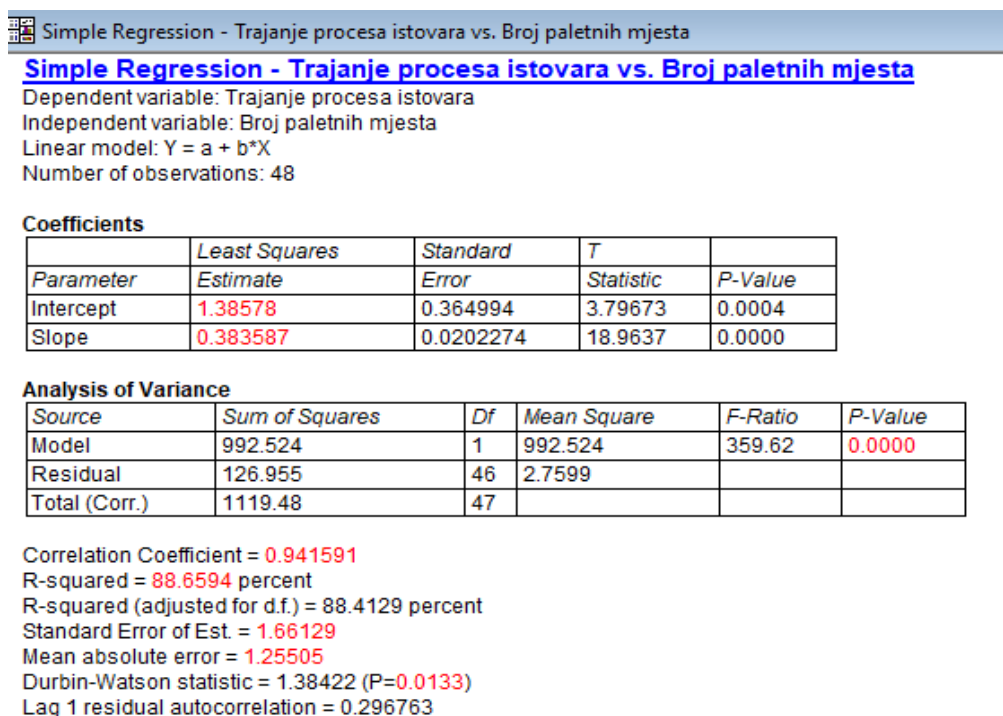
Slika 32. Nova jednadžba modela linearne regresije

Nakon izbacivanja tri podatka nova jednadžba modela glasi (10):

$$y = 1,3858 + 0,3836 x \quad (10)$$

gdje je:

- $y \rightarrow$ *trajanje procesa istovara*,
- $x \rightarrow$ *broj paletnih mjesta*.




Slika 33. Statistički pokazatelji nove jednadžbe modela linearne regresije

Iz tablica je vidljivo da izbacivanjem tri podatka se povećao koeficijent korelacije i koeficijent determinacije. Koeficijent korelacije sada iznosi 0,9416 dok koeficijent determinacije iznosi 0,8866. P-vrijednost Durbin-Watson testa sada iznosi 0,0133 te ne možemo tvrditi da za ovaj model linearne regresije ne postoji serijska autokorelacija odstupanja (residuala) sa 95% pouzdanosti jer p-vrijednost je manja od 0,05.

4.5.1. Testiranje normalnosti podataka

U nastavku je napravljen test da li se podaci o trajanju procesa istovara kreću po normalnoj distribuciji. Prikazan je histogram podataka trajanja procesa opisan s krivuljom normalne distribucije.



Slika 34. Histogram trajanja procesa istovara

Napravljen je „Shapiro-Wilk“ test, koji se temelji na usporedbi kvantila usklađene normalne raspodjele s kvantilima podataka.

Tests for Normality for Trajanje procesa istovara		
Test	Statistic	P-Value
Shapiro-Wilk W	0.896874	0.000331348

Slika 35. Shapiro-Wilk test

Budući da je najmanja P-vrijednost među testovima manja od 0,05, možemo odbaciti ideju da podaci o trajanje procesa istovara dolaze iz normalne distribucije razinom pouzdanosti od 95%.

Goodness-of-Fit Tests for Trajanje procesa istovara	
Kolmogorov-Smirnov Test	
	Normal
DPLUS	0.193032
DMINUS	0.133067
DN	0.193032
P-Value	0.0447119

Slika 36. Kolmogorov-Smirnov test

Napravljen je i „Kolmogorov - Smirnov“ test koji također sa razinom pouzdanosti od 95% odbacuje ideju da podaci trajanja procesa istovara su normalno distribuirani.

4.5.2. Analiza varijance izmjerenog trajanja procesa istovara i modela predviđanja

Analiza varijance je statistički postupak kojim se provjeravaju promjene aritmetičkih sredina uzoraka. Dakle, gleda se da li je varijabilitet rezultata nastao slučajnim variranjem (kao


posljedica eksperimentalne pogreške-osobne razlike ispitanika, pogreška mjerenja tj. svi nekontrolirani izvori varijabiliteta) ili je nastao pod specifičnim utjecajem nezavisne varijable. Zato je za svaki uzorak potrebno odrediti interval variranja (aritmetičke sredine tog uzorka oko prave aritmetičke sredine populacije, preko standardne pogreške aritmetičke sredine), te vidjeti da li postoji zona prekrivanja među uzorcima. Ako neki uzorak odstupa od ostalih toliko da je šansa da se takvo što dogodi po slučaju jako mala (5 ili 1 %), onda zaključujemo da vjerojatno nije uzet iz iste populacije. Analiza varijance je postupak usporedbe više uzoraka pri čemu svaki uzorak predstavlja zasebni osnovni skup, odnosno populaciju.

ANOVA je moćni postupak za analizu kvalitete regresijskog modela. Svrha je nalaženje faktora koji najviše utječu na model (primjer regresija), reducira se na testiranje razlike između srednjih vrijednosti više uzoraka, u principu uzorci nisu nezavisni i dobiveni su dizajnom eksperimenta (kada se kontrolira vrijednost faktora). Varijanca unutar modela može se izdvojiti na onu unutar grupe i na onu između grupa, a zatim se ti dijelovi stavljaju u odnos tako otkrivajući činjenice o modelu.[13] ANOVA služi i za provjeru modela (lack of fit test).

TOTALNA VARIJABILNOST $SS_{TOTAL} = \text{VARIJABILNOST REZIDUALA (POGREŠKE-ERROR)} SS_{RESIDUAL} + \text{VARIJABILNOST OBJAŠNJENA REGRESIJSKIM MODELOM} SS_{REG}$ (11)

$$SS_{UKUPNO} = \sum (Y_i - \bar{Y})^2 = SS_{ODSTUPANJA} + SS_{REGRESIJE} = \sum (Y_i - \hat{Y}_i)^2 + \sum (\hat{Y}_i - \bar{Y})^2 \quad (11)$$

Linearna regresija



$$\hat{Y}_i = a + bX_i$$

Slika 37. Prikaz odstupanja (residuala) modela linearne regresije[13]

$\hat{Y}_i - Y_i$ je residual ili pogreška koja nastaje kada predviđamo Y u zavisnosti od X. Reziduali predstavljaju onaj dio varijabilnosti koji nije moguće objasniti modelom. Reziduali se moraju pažljivo provjeriti jer oni odražavaju ispunjavanje pretpostavki modela – najbolje grafički (posebno za male uzorke kada numerički postupci nisu odgovarajući).[13]

Tablica 4. Usporedba izmjerenog trajanja istovara i dobivenog modelom

Redni broj	Broj paletnih mjesta (x)	Izmjereno trajanje procesa istovara (minute)	Trajanje procesa istovara po modelu: $y=1,3858 + 0,3836x$ (minute)	Razlika izmjerenog i modela (minute)	Razlika izmjerenog i modela u postocima (%)
1.	26	10	11.35904	-1.359042	-14%
2.	4	2	2.920128	-0.920128	-46%
3.	1	1	1.769367	-0.769367	-77%
4.	4	3	2.920128	0.079872	3%
5.	16	9	7.523172	1.476828	16%
6.	1	1	1.769367	-0.769367	-77%
7.	33	14	14.04415	-0.044151	0%
8.	33	14	14.04415	-0.044151	0%
9.	7	4	4.070889	-0.070889	-2%
10.	28	12	12.12622	-0.126216	-1%
11.	3	2	2.536541	-0.536541	-27%
12.	3	2	2.536541	-0.536541	-27%
13.	3	4	2.536541	1.463459	37%
14.	2	1	2.152954	-1.152954	-115%
15.	3	2	2.536541	-0.536541	-27%
16.	5	5	3.303715	1.696285	34%
17.	1	1	1.769367	-0.769367	-77%
18.	6	2	3.687302	-1.687302	-84%
19.	32	12	13.66056	-1.660564	-14%
20.	33	12	14.04415	-2.044151	-17%
21.	31	12	13.27698	-1.276977	-11%
22.	15	7	7.139585	-0.139585	-2%
23.	24	14	10.59187	3.408132	24%
24.	33	19	14.04415	4.955849	26%
25.	3	3	2.536541	0.463459	15%
26.	32	14	13.66056	0.339436	2%
27.	10	9	5.22165	3.77835	42%
28.	4	4	2.920128	1.079872	27%
29.	9	4	4.838063	-0.838063	-21%
30.	3	4	2.536541	1.463459	37%
31.	7	5	4.070889	0.929111	19%

32.	26	11	11.35904	-0.359042	-3%
33.	1	1	1.769367	-0.769367	-77%
34.	32	16	13.66056	2.339436	15%
35.	30	10	12.89339	-2.89339	-29%
36.	1	1	1.769367	-0.769367	-77%
37.	24	10	10.59187	-0.591868	-6%
38.	3	2	2.536541	-0.536541	-27%
39.	6	2	3.687302	-1.687302	-84%
40.	24	10	10.59187	-0.591868	-6%
41.	11	4	5.605237	-1.605237	-40%
42.	3	4	2.536541	1.463459	37%
43.	5	4	3.303715	0.696285	17%
44.	16	10	7.523172	2.476828	25%
45.	12	8	5.988824	2.011176	25%
46.	4	2	2.920128	-0.920128	-46%
47.	28	9	12.12622	-3.126216	-35%
48.	12	5	5.988824	-0.988824	-20%
49.	33	23	14.044151	8.955849	39%
50.	34	21	14.427738	6.572262	31%
51.	23	16	10.208281	5.791719	36%

Analysis of Variance with Lack-of-Fit

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Model	1392.57	1	1392.57	262.86	0.0000
Residual	259.59	49	5.29776		
Lack-of-Fit	139.099	20	6.95493	1.67	0.1005
Pure Error	120.492	29	4.15489		
Total (Corr.)	1652.16	50			

The StatAdvisor

The lack of fit test is designed to determine whether the selected model is adequate to describe the observed data, or whether a more complicated model should be used. The test is performed by comparing the variability of the current model residuals to the variability between observations at replicate values of the independent variable X. Since the P-value for lack-of-fit in the ANOVA table is greater or equal to 0.05, the model appears to be adequate for the observed data at the 95.0% confidence level.

Slika 38. Analiza varijance preko „Lack of fit“ testa

$$F = \frac{\text{lack-of-fit sum of squares/degrees of freedom}}{\text{pure-error sum of squares/degrees of freedom}}$$

Slika 39. Formula za izračun parametra F (12)

$$F = \frac{\text{Suma kvadrata odstupanja regresijskog modela} / \text{stupnjevi slobode gibanja}}{\text{Suma kvadrata odstupanja resiudala} / \text{stupnjevi slobode gibanja}} \quad (12)$$

Pomoću programa „Statgraphics 18“ napravljena je analiza varijance pomoću „lack of fit test“ za cijeli skup podataka. Usporedbom rezultata testa i ANOVA tablica ustavovljeno je da je model adekvatan za skup podataka sa razinom pouzdanosti od 95%.

4.6. Trajanje procesa preuzimanja u depozitnom skladištu

Proces preuzimanja robe sastoji se od fizičkog i sistemskog preuzimanja. Fizičko preuzimanje robe podrazumijeva pregled količine, roka trajanja i stanja robe. Ako jedan od nabrojenih kriterija nije zadovoljen piše se zapisnik. Procese fizičkog i sistemskog preuzimanja obavlja kontrolor ulaza, on to može raditi paralelno ili slijedno. Pod pojmom paralelno preuzimanje smatra se da kontrolor ulaza prvo fizički pregleda jednu vrstu artikla, to jest jednu stavku na otpremnici te je odmah zatim sistemski zaprimi. Dok pod pojmom slijedno preuzimanje, kontrolor ulaza prvo fizički pregleda svu robu koja se nalazi na otpremnici te je potom sistemski zaprimi. Sistemsko preuzimanje podrazumijeva da kontrolor ulaza pomoću skenera „unese“ robu u WMS sustav te potvrdom zaprimanja vrši se ispis primke. U pravilu roba koja se preuzima dolazi na paletama, ako se na jednoj paleti nalazi isti artikl govorimo o “full pick” paleti te prilikom preuzimanja potrebno je zalijepiti samo jednu labelu. Ako je roba složena po slojevima tako da na jednoj paleti se nalazi jedna vrsta artikla, ali palete su poredane jedna na drugu radi se o “sandwich” paleti te je na svaku vrstu artikla potrebno zalijepiti labelu. Postoji i treći najrjeđi slučaj, a to je “mix” paleta gdje na jednoj paleti se nalazi više različitih artikala.

Podaci koji su prikupljivani prilikom mjerenja trajanja procesa preuzimanja robe:

- broj otpremnice,
- dobavljač,
- datum dolaska dobavljača,
- vrijeme početka procesa,
- vrijeme kraja procesa,
- trajanje procesa u minutama,
- način preuzimanja robe,
- potreba za pisanjem zapisnika,
- način pakiranja robe.

Tablica preuzimanja robe										
Dobavljač	Broj otpremnice	Način preuzimanja robe	Nepravilnosti u vezi robe	Full pick	Sandwich	Mix	Datum	Vrijeme početka procesa	Vrijeme kraja procesa	Trajanje procesa (minute)
DOBAVLJAČ 1	4194000	slijedno	ne	26			10/4/2018	10:18	10:46	28
DOBAVLJAČ 2	2018-RTL-000152	slijedno	ne	4			10/4/2018	10:59	11:08	9
DOBAVLJAČ 3	87/1/1	slijedno	ne	1			10/4/2018	11:15	11:20	5
DOBAVLJAČ 4	2018-104-002725 ; 2018-182-000007	slijedno	ne	4			10/4/2018	11:31	11:41	10
DOBAVLJAČ 5	96	slijedno	ne	16			10/4/2018	12:10	12:31	21
DOBAVLJAČ 6	8/18	slijedno	ne	1			10/4/2018	12:44	12:46	2
DOBAVLJAČ 7	3623	slijedno	ne	33			10/4/2018	13:12	13:29	17
DOBAVLJAČ 8	DA 18013230	slijedno	ne	33			10/5/2018	9:58	10:08	10
DOBAVLJAČ 9	30521-07002229-18	slijedno	ne	7			10/5/2018	10:23	10:32	9
DOBAVLJAČ 10	18448	slijedno	da(zapisnik)	28			10/5/2018	10:53	11:27	34
DOBAVLJAČ 11	00040486	slijedno	ne	1	2		10/5/2018	11:28	11:49	21
DOBAVLJAČ 12	10-2018-2770	slijedno	ne	2	1		10/5/2018	12:43	12:58	15
DOBAVLJAČ 13	771	slijedno	ne			3	10/5/2018	13:05	13:16	11
DOBAVLJAČ 14	50541-07000857-18	slijedno	ne	2			10/10/2018	9:19	9:25	6
DOBAVLJAČ 15	80011160	slijedno	ne	3			10/10/2018	9:31	9:39	8
DOBAVLJAČ 16	IK0802957	paralelno	ne	4	1		10/10/2018	9:54	10:19	25
DOBAVLJAČ 17	20427339	slijedno	ne	1			10/10/2018	10:35	10:43	8
DOBAVLJAČ 18	682-1/2018 ; 682/2018	slijedno	ne	6			10/10/2018	10:52	11:06	14
DOBAVLJAČ 19	1047/18 ; 1046/18	slijedno	ne	32			10/10/2018	11:28	11:49	21
DOBAVLJAČ 20	PRO18015790	slijedno	ne	33			10/10/2018	12:08	12:22	14
DOBAVLJAČ 21	2018-ZG-167273-OTP	slijedno	da(zapisnik)	6	9		10/10/2018	12:52	13:36	44
DOBAVLJAČ 22	149/18	slijedno	ne	31			10/10/2018	13:06	13:22	16
DOBAVLJAČ 23	1902580-183-190	paralelno	ne		3		10/11/2018	15:20	15:34	14
DOBAVLJAČ 24	961-2122	slijedno	ne	24			10/11/2018	15:46	15:54	8
DOBAVLJAČ 25	6266847803	paralelno	ne	20	12	1	10/11/2018	16:21	17:45	84
DOBAVLJAČ 26	5030-ISK1-300	slijedno	ne	33			10/11/2018	17:03	17:17	14
DOBAVLJAČ 27	PRO18015915	slijedno	ne	1			10/12/2018	9:18	9:23	5
DOBAVLJAČ 28	PRO18015940	slijedno	ne	32			10/12/2018	9:24	10:15	51
DOBAVLJAČ 29	9002531033	slijedno	ne	32			10/12/2018	10:23	11:17	54
DOBAVLJAČ 30	1729 ; 6081	slijedno	da(zapisnik)	8	2		10/12/2018	10:32	11:01	29
DOBAVLJAČ 31	10-2018-2819	slijedno	ne	2	2		10/12/2018	11:23	11:31	8
DOBAVLJAČ 32	2018-ZG-167350-OTP	slijedno	ne	5	4		10/12/2018	11:50	12:07	17
DOBAVLJAČ 33	87	slijedno	ne	30			10/12/2018	12:10	12:26	16
DOBAVLJAČ 34	A30043138	slijedno	ne		3		10/12/2018	12:19	12:36	17
DOBAVLJAČ 35	222	slijedno	ne	7			10/12/2018	12:28	12:42	14
DOBAVLJAČ 36	20002318	slijedno	ne	1			10/12/2018	12:33	12:38	5
DOBAVLJAČ 37	9002536264 ; 9002531748	slijedno	ne	26			10/12/2018	12:57	13:24	27
DOBAVLJAČ 38	82234528 ; 82237206	slijedno	ne	24			10/12/2018	13:00	13:18	18
DOBAVLJAČ 39	70-891076	slijedno	ne	2	1		10/15/2018	9:16	9:24	8
DOBAVLJAČ 40	OTK18-F-04925	paralelno	ne	2	1		10/15/2018	9:44	9:54	10
DOBAVLJAČ 41	61/2018	paralelno	ne	6			10/15/2018	10:08	10:18	10
DOBAVLJAČ 42	4100014592	paralelno	ne	4	1		10/15/2018	10:17	10:28	11
DOBAVLJAČ 43	2018-12733	slijedno	ne	23	1		10/15/2018	10:39	10:56	17
DOBAVLJAČ 44	80196401	slijedno	ne	34			10/15/2018	10:46	11:14	28
DOBAVLJAČ 45	2.536 ; 2.535	slijedno	ne	23			10/15/2018	11:24	11:47	23
DOBAVLJAČ 46	695/2018	slijedno	ne	11			10/15/2018	12:08	12:20	12
DOBAVLJAČ 47	2018-ZG-167446-OTP	slijedno	ne	9	7		10/16/2018	10:56	11:18	22
DOBAVLJAČ 48	2100407237	slijedno	ne	28			10/16/2018	11:11	11:22	11
DOBAVLJAČ 49	2469	slijedno	ne	4			10/16/2018	11:32	11:52	20
DOBAVLJAČ 50	180R0001084	slijedno	ne	12			10/16/2018	11:40	11:50	10
DOBAVLJAČ 51	10001-734-6305-18	slijedno	ne	12			10/16/2018	11:56	12:05	9

Slika 40. Tablica preuzimanja robe

Nakon što je obavljeno mjerenje trajanja procesa preuzimanja robe, preko broja otpremnice povezani su podaci mjerenja sa značajkama na otpremnici.

Značajke koje se nalazi pohranjene u bazi WMS sustava su:

- otpremnica (broj otpremnice),
- narudžba (broj Konzum narudžbe),
- primka (broj Konzum primke),
- dobavljač (naziv dobavljača),
- SSCC (broj sscs labele/naljepnice koja se lijepi na artikle za svaku paletu),
- šifra artikla (Konzum interna šifra artikla),
- naziv artikla,
- barkod artikla,
- naručena količina (predstavlja ukupnu naručenu količinu tog artikla po narudžbi),
- zaprimljena količina (predstavlja zaprimljenu količinu jedne vrste artikla po jednoj paleti),
- mjerna jedinica (KO - komadi),
- KU_MP (količina u kutiji, matični podatak),
- PL_MP (količina na paleti, matični podatak),
- KU_ZAP (zaprimljeno kutija prema matičnom podatku),
- PL_ZAP (zaprimljeno paleta prema matičnom podatku),
- zaprimljeno paleta (ambalaža) (broj zaprimljenih paleta),
- zaprimljeno artikala (broj različitih vrsta artikala po narudžbi).

OTPREMNICA	DOBAVLJAČ	ZAPRIMLJENO ARTIKALA	ZAPRIMLJENO PALETA (AMBALAŽA)	Values		KUTIJA ZAPRIMLJENO	PALETA ZAPRIMLJENO
				SSCC/STAVKE			
87		4		30	30	1984	30
96		4		16	16	316	16
222		4		7	7	352	7
771		8		0	8	196	1.439407407
1729		5		6	6	308	3.733333333
2469		4		4	4	108	3.333333333
2535		1		3	3	126	3
2536		3		20	20	840	20
3623		4		33	33	1136	33
6081		5		6	6	396	4.029761905
18448		10		28	28	1296	28
4194000		11		26	26	4320	26
20002318		1		1	1	60	1
20427339		1		1	1	54	1
80011160		3		3	3	540	3
80196401		3		34	34	2490	33.34567901
82234528		1		10	10	627	9.796875
82237206		1		14	14	874	13.65625
2100407237		1		28	28	1764	28
4100014592		3		3	3	972	3
6266847803		43		53	57	3104	30.32906321
9002531033		18		32	32	1857	32
9002531748		1		14	14	504	14
9002536264		8		12	12	627	12
00040486		9		9	9	200	2.718181818
10001-734-6305-18		6		12	12	990	11.5
10-2018-2770		5		5	5	194	2.490873016
10-2018-2819		6		6	6	316	4.425
1046/18		3		21	21	2044	20.44

Slika 41. Pivot tablica koja povezuje snimane podatke sa značajkama na otpremnici

Pivot tablica preuzimanja robe prikazuje podatke o:

- broju otpremnice,
- nazivu dobavljača,
- broju različitih zaprimljenih artikala po otpremnici,
- broju zaprimljenih paleta (ambalaža),
- broju zaprimljenih stavaka / labela,
- broju zaprimljenih kutija,
- broju zaprimljenih paleta (izračun iz matičnih podataka).

Prilikom mjerenja trajanja procesa preuzimanja uočeno je da značajke koje najviše utječu na vrijeme trajanja procesa preuzimanja su broj paleta, broj različitih artikala i broj labela (sscc/stavke) koje su lijepljene na artikle.

4.7. Izračun broja paletnih mjesta

Na primjeru jedne narudžbe objašnjen je model generiranja broja „full pick“ paleta. Kao što je već spomenuto „full pick“ paleta je način pakiranja robe gdje na jednoj paleti se nalazi jedna vrsta artikla. Na slici se nalazi primjer „full pick“ paleta.



Slika 42. Primjer „full pick“ palete

Na primjeru jedne narudžbe od dobavljača X objasniti će se način povezivanja značajki narudžbe sa brojem „full pick“ paleta. Prvo su prikazani izmjereni podaci za trajanje procesa preuzimanja tog dobavljača.

Tablica 5. Izmjereni podaci za jednu narudžbu

Broj otpremnice	87
Dobavljač	X
Način preuzimanja robe	slijedno
Nepravilnosti u vezi robe	ne
Način pakiranja robe	30 „full pick“ paleta
Datum	12.10.2018.
Vrijeme početka procesa	12:10
Vrijeme kraja procesa	12:26
Trajanje procesa	16 minuta

Preko broja otpremnice povučene su iz baze podataka značajke na otpremnici i kreirana nova tablica:

Tablica 6. Značajke robe za jednu narudžbu

OTPREMNICA	PRIMKA	ŠIFRA ARTIKLA	NARUČENA KOLIČINA	ZAPRIMLJENA KOLIČINA	KUTIJA ZAPRIMLJENO	PALETA ZAPRIMLJENO	KUTIJA MATIČNI PODATAK	PALETA MATIČNI PODATAK
87	223419	90290974	8640	8640	1080	15	8	576
87	223419	90290981	2352	2352	392	7	6	336
87	223419	90293557	3072	3072	384	6	8	512
87	223419	90293583	1024	1024	128	2	8	512

Legenda:

- **Otpremnica** – označava broj otpremnice
- **Primka** – označava broj primke
- **Šifra artikla** – označava šifru artikla
- **Naručena količina** – označava naručenu količinu tog artikla po komadima
- **Zaprimljena količina** – označava zaprimljenu količinu tog artikla po komadima
- **Kutija zaprimljeno** – označava broj zaprimljenih kutija u kojima se nalaze artikli
- **Paleta zaprimljeno** – označava broj zaprimljenih paleta jednog artikla
- **Kutija matični podatak** – označava koliko komada tog artikla stane u jednu kutiju
- **Paleta matični podatak** – označava koliko komada tog artikla stane na jednu paletu

Iz tablice je vidljivo da u ovoj narudžbi su naručena 4 različita artikla u količinama od 8640, 2352, 3072 i 1024 komada. Formula za izračun broja „full pick“ paleta (13):

$$\text{Broj full pick paleta} = \frac{a}{b} = \frac{\text{Naručena količina jedne vrste artikla}}{\text{Količina te vrste artikla koja stane na jednu paletu}} \quad (13)$$

Za artikl pod šifrom 90290974 gdje je naručeno 8640 komada toga artikla slijedi izračun broja „full pick“ paleta:

$a = 8640$ komada,

$b = 576$ komada (očitano iz matičnih podataka),

$$\frac{a}{b} = \frac{8640}{576} = 15 \text{ full pick paleta}$$

Za naručenu količinu 2352 komada artikla pod šifrom 90290981, izračun broja „full pick“ paleta glasi:

$$a = 2352 \text{ komada},$$

$$b = 336 \text{ komada (očitano iz matičnih podataka)},$$

$$\frac{a}{b} = \frac{2352}{336} = 7 \text{ full pick paleta}$$

Za naručenu količinu 3072 komada artikla pod šifrom 90293557, izračun broja „full pick“ paleta glasi:

$$a = 3072 \text{ komada},$$

$$b = 512 \text{ komada (očitano iz matičnih podataka)},$$

$$\frac{a}{b} = \frac{3072}{512} = 6 \text{ full pick paleta}$$

Za naručenu količinu 1024 komada artikla pod šifrom 90293583, izračun broja „full pick“ paleta glasi:

$$a = 1024 \text{ komada},$$

$$b = 512 \text{ komada (očitano iz matičnih podataka)},$$

$$\frac{a}{b} = \frac{1024}{512} = 2 \text{ full pick paleta}$$

Nakon što smo izračunali broj „full pick“ paleta za svaku vrstu artikla po ovaj narudžbi slijedi izračun broja „full pick“ paleta za cijelu narudžbu (4 vrste artikla) (14):

$$n = 4 \text{ (broj različitih vrsta artikala)},$$

$$\sum_{n=1}^4 (\text{broj full pick paleta po jednoj vrsti artikla}) = 15 + 7 + 6 + 2 = 30 \quad (14)$$

Iz naručene količine određene vrste artikla i broja komada tog artikla koji stane na jednu paletu može se izračunati broj „full pick“ paleta koji će stići u skladište za jednu narudžbu. Na primjeru ove narudžbe izračunato je da će doći 30 „full pick“ paleta što se poklapa s brojem paleta koji je zabilježen mjerenjem. Uvjet da bi se mogao predviđati točan broj „full pick“ paleta je da dobavljač u potpunosti isporuči naručenu količinu robe. U protivnom ne možemo predviđati točan broj „full pick“ paleta.

Što se tiče „sandwich“ i „mix“ paleta jako je teško predvidjeti kako će roba doći zapakirana. „Sandwich“ i „mix“ način pakiranja robe koristi se kada količine jedne vrste artikla nisu dovoljne za popuniti paletno mjesto, a želi se što više iskoristiti kapacitet paletnog mjesta. Tako kod „sandwich“ paleta artikli se slažu po slojevima i na jednom sloju (paleti) se nalazi jedna vrsta artikla. Dok kod „mix“ paleta na jednoj paleti se nalazi više različitih vrsta artikala. Formula za broj „full pick“ paleta u biti govori o popunjenosti paletnog mjesta, ako je rezultat manji od 1 znači da kapacitet paletnog mjesta nije potpuno iskorišten te će vrlo vjerojatno roba biti složena na „sandwich“ ili „mix“ način. U nastavku je prikazan primjer dolaska jednog dobavljača za kojeg je zabilježeno da je dio robe zapakiran na „sandwich“ palete.

Prvo su prikazani izmjereni podaci za tog dobavljača:

Tablica 7. Izmjereni podaci za jednu narudžbu

Broj otpremnice	00040486
Dobavljač	Y
Način preuzimanja robe	slijedno
Nepravilnosti u vezi robe	ne
Način pakiranja robe	1 „full pick“ , 2 „sandwich“ palete
Datum	5.10.2018.
Vrijeme početka procesa	11:28
Vrijeme kraja procesa	11:49
Trajanje procesa	21 minuta

Zatim su preko broja otpremnice povezani podaci o značajkama robe za tu narudžbu:

Tablica 8. Značajke robe za jednu narudžbu

OTPREMNICA	PRIMKA	ŠIFRA ARTIKLA	NARUČENA KOLIČINA	ZAPRIMLJENA KOLIČINA	KUTIJA ZAPRIMLJENO	PALETA ZAPRIMLJENO	KUTIJA MATIČNI PODATAK	PALETA MATIČNI PODATAK
00040486	222908	90158078	360	360	30	0,2727	12	1320
00040486	222908	90158092	756	756	36	0,8	21	945
00040486	222908	90158095	256	256	16	0,333	16	768
00040486	222908	90158099	480	480	40	0,666	12	720
00040486	222908	90182308	144	144	12	0,1	12	1440
00040486	222908	90202611	22	22	22	0,1818	1	121
00040486	222908	90220218	11	11	11	0,0909	1	121
00040486	222908	90220228	11	11	11	0,0909	1	121
00040486	222908	90220230	22	22	22	0,1818	1	121

Iz tablice je vidljivo da se narudžba sastoji od 8 različitih artikala, prikazana je popunjenost paletnog mjesta za svaku vrstu artikla (15).

$$\frac{a}{b} = \frac{\text{Naručena količina jedne vrste artikla}}{\text{Količina te vrste artikla koja stane na jednu paletu}} = \text{iskorištenost paletnog mjesta (broj full pick paleta)} \quad (15)$$

Tablica 9. Izračun popunjenosti paletnih mjesta za jednu narudžbu (16)

ŠIFRA ARTIKLA	NARUČENA KOLIČINA JEDNE VRSTE ARTIKLA (a)	BROJ KOMADA TOG ARTIKLA KOJI STANE NA JEDNU PALETU (b)	ISKORIŠTENOST PALETNOG MJESTA (a/b)
90158078	360	1320	0,2727
90158092	756	945	0,8
90158095	256	768	0,333
90158099	480	720	0,666
90182308	144	1440	0,1
90202611	22	121	0,1818
90220218	11	121	0,0909
90220228	11	121	0,0909
90220230	22	121	0,1818

$n = 9 \Rightarrow$ broj različitih vrsta artikala,

$$\sum_{n=1}^9 \left(\frac{a}{b}\right) = 0,27 + 0,8 + 0,33 + 0,66 + 0,1 + 0,18 + 0,09 + 0,09 + 0,18 = 2,718 \quad (16)$$

Sumiranjem iskorištenosti kapaciteta paletnog mjesta za svaku vrsta artikla po narudžbi, dobiveni je rezultat od 2,718 paletnih mjesta. Ovim izračunom može se pretpostaviti da će dio artikala doći zapakiran kao „sandwich“ ili „mix“ paleta, ali ne možemo točno reći koji je način pakiranja. Mjerenjem je ustanovljeno da je za ovu narudžbu došla jedna „full pick“ paleta i dvije „sandwich“. A izračunom je dobiveno da je iskorištenost paletnih mjesta 2,718. Usporedbom tih dvaju rezultata, zaključak je da za slučajeve gdje je omjer naručene količine i količine koja stane na jednu paletu manji od jedan pretpostavka je da će dio robe biti zapakiran kao „sandwich“ ili „mix“ paleta, ali ne može se znati točan broj kako je koja roba zapakirana.

U nastavku je za sve narudžbe napravljena usporedba broja paletnih mjesta izračunatih preko formule i broja paletnih mjesta dobivenih stvarnim mjerenjem. Za 51 slučaj je izmjeren stvarni broj paletnih mjesta koji je stigao u dostavnom vozilu te su ti rezultati uspoređeni sa rezultatima dobivenih preko omjera naručene količine za jednu vrstu artikla i količine te vrste artikla koja stane na jednu paletu.

Tablica 10. Usporedba izmjerenih broja paletnih mjesta i dobivenih modelom

Izmjereni broj paletnih mjesta	Broj paletnih mjesta dobiven modelom	Razlika izmjerenog broja paletnih mjesta i dobivenog modelom
26	26	0
4	3.533333333	0.466667
1	0.4	0.6
4	3.222	0.788
16	16	0
1	0.011363636	0.988636
33	33	0
33	33	0
7	6.25	0.75
28	28	0

3	2.718	0.282
3	2.490873016	0.509127
3	1.439	1.561
2	2	0
3	3	0
5	3.023809524	1.97619
1	1	0
6	6	0
32	31.36	0.64
33	33	0
31	30.90625	0.09375
15	22.67435897	-7.67436
24	24	0
33	33	0
3	1.466	1.534
33	30.329	2.671
32	32.8333	-0.8333
10	7.76	2.24
4	4.425	-0.425
9	11.66666667	-2.66667
3	2.698958333	0.301042
7	7	0
26	26	0
1	1	0
32	32	0
30	30	0
1	1	0
24	23.45	0.55
3	3.246666667	-0.24667
6	4	2


24	23.699	0.301
23	23	0
11	11	0
3	3.25	-0.25
5	3	2
34	33.45	0.55
16	21.96	-5.96
12	12	0
4	3.33	0.67
28	28	0
12	11.5	0.5

Pomoću programa „Microsoft excel“ i funkcije „countif“ prebrojani su svi slučajevi gdje je apsolutna razlika broja paletnih mjesta dobivenih mjerenjem i formulom manja od jedan. Takvih slučajeva je 43 što čini 84,32 % od ukupnog broja slučajeva. Potom su izračunati statistički pokazatelji za oba skupa podataka.

Two Sample Comparison - Izmjereni broj paletnih mjesta & Broj pal. mjesta preko formule		
Summary Statistics		
	Izmjereni broj paletnih mjesta	Broj pal. mjesta preko formule
Count	51	51
Average	14.5686	14.4921
Standard deviation	12.3114	12.5547
Coeff. of variation	84.5061%	86.6314%
Minimum	1.0	0.0113636
Maximum	34.0	33.45
Range	33.0	33.4386
Std. skewness	1.2291	0.98938
Std. kurtosis	-2.24787	-2.38776


Slika 43. Usporedba izmjerenih broja paletnih mjesta i dobivenih modelom

Na prvu je vidljivo da su podaci o aritmetičkoj sredini, standardnoj devijaciji, koeficijentu varijacije veoma slični, nakon toga je pomoću t testa napravljeno testiranje hipoteze o razlici aritmetičkih sredina ova dva skupa za razinu značajnosti 0,05.



Slika 44. Testiranje nul hipoteze o jednakosti aritmetičkih sredina

Testiranjem statističke hipoteze o jednakosti aritmetičkih sredina ova dva skupa dobivena je t vrijednost 0,031 za koju s razinom pouzdanosti od 95% može se tvrditi da ne postoji značajna razlika aritmetičkih sredina ova dva skupa.



Slika 45. Kvantil - Kvantil dijagram

Ovaj dijagram grafički prikazuje jesu li dva sva skupa podataka iz populacija s zajedničkom distribucijom. Prikazana je referentna linija od 45 stupnjeva, ako dva skupa dolaze iz populacija s istom distribucijom oni bi se trebali nalaziti blizu te linije. Što su veća odstupanja od referentne linije to je veći dokaz da podaci dolaze iz različitih distribucija. Iz dijagrama je vidljivo da postoje dva podataka koja odstupaju. U ta dva slučaja izmjereni broj paletnih

mjesta su bili 15 i 16, a preko modela za izračun broja paletnih mjesta dobiveno je 22,67 i 21,96 paletnih mjesta. To su velika odstupanja s obzirom na ostale rezultate, analizom je utvrđeno da su ta dva slučaja zabilježena za istog dobavljača stoga bi trebalo provjeriti ispravnost matičnih podataka o količinama koje stanu na jednu paletu za artikle u tim narudžbama.


4.8. Analiza prikupljenih podataka o trajanju procesa preuzimanja

Analizom trajanja procesa preuzimanja dobiveni su sljedeći rezultati:


One Variable Analysis - Trajanje procesa preuzimanja	
Summary Statistics for Trajanje procesa preuzimanja	
Count	51
Average	18.0392
Standard deviation	14.4568
Coeff. of variation	80.1408%
Minimum	2.0
Maximum	84.0
Range	82.0
Std. skewness	7.46081
Std. kurtosis	12.3761

Slika 46. Analiza trajanje procesa preuzimanja

Prosječno vrijeme trajanja preuzimanja za 51 slučaj iznosi 18,04 minute sa standardnom devijacijom od 14,46 minuta. Minimalno trajanja preuzimanja iznosi 2 minute, a maksimalno 84 minute. Koeficijent varijacije iznosi 80,14%. A mjere nagnutosti i ispupčenosti dijagrama normalne distribucije podataka se nalaze izvan raspona $<-2,2>$ iz čega možemo zaključiti da podaci nisu normalno distribuirani.



Slika 47. Histogram trajanja procesa preuzimanja




Slika 48. „Box and whisker“ dijagram za trajanje procesa preuzimanja

Iz „box and whisker“ dijagrama vidljivo je da postoje 4 vremena koja odudaraju od ostalih („outliers“). Ta vremena su posebno zanimljiva za promatranje jer daju uvid kako značajke na otpremnici utječu na trajanje procesa preuzimanja robe. Stoga su prikazana ta 4 podatka kako bi se detaljnije analizirali.

Tablica 11. Najduža vremena preuzimanja i njihovi parametri

Broj otpremnice	Broj paletnih mjesta	Broj različitih artikala	Broj labela (sscc/stavke)	Vrijeme trajanja procesa preuzimanja
6266847803	33	43	57	84 min
9002531033	32	18	32	54 min
PR018015940	32	14	32	51 min
2018-ZG-167273- OTP	15	7	25	44 min

Za jednog dobavljača bila je potreba za pisanjem zapisnika stoga vrijeme trajanja procesa preuzimanja je uvećano za vrijeme potrebno za pisanje zapisnika. Taj slučaj je izuzet iz daljih razmatranja i analizirana su samo tri slučaja sa najvećim vremenima trajanja preuzimanja. Prvo je napravljena statistička analiza za broj različitih artikala, broj paletnih mjesta i broj labela.



Slika 49. Histogram broja različitih artikala


Histogram za broj različitih artikala prikazuje raspodjelu učestalosti pojave određenog broja artikala po otpremnici. Iz dijagrama se vidi da postoje dva slučaja od 43 i 18 različitih artikala koji odskakuju od prosjeka. Ti slučajevi odgovaraju najdužim trajanjima procesa preuzimanja te iz toga se može zaključiti da postoji određena veza između te dvije varijable.

One Variable Analysis - Broj različitih artikala	
Summary Statistics for Broj različitih artikala	
Count	51
Average	5.33333
Standard deviation	6.58989
Coeff. of variation	123.56%
Minimum	1.0
Maximum	43.0
Range	42.0
Std. skewness	11.758
Std. kurtosis	31.1448

Slika 50. Analiza broja različitih artikala

Statistički pokazatelji za broj različitih artikala govore da prosječan broj različitih artikala iznosi 5,33 sa standardnom devijacijom od 6,59. Koeficijent varijacije iznosi 123,56%. Izmjereni minimalan broj različitih artikala je 1, a maksimalan broj različitih artikala je 43. Iz histograma raspodjele broja različitih artikala, ustanovljeno je da vrijednosti najvećeg broja različitih artikala odgovaraju najdužim vremenima trajanja procesa preuzimanja.

Zatim je napravljena statistička analiza za broj paletnih mjesta:




Slika 51. Histogram broja paletnih mjesta

Histogram prikazuje učestalost pojave određenog broja paletnih mjesta za 51 slučaj. Iz dijagrama se može zaključiti da tri najduža vremena trajanja procesa preuzimanja zabilježena su za najveći broj paletnih mjesta (33,32,32).

One Variable Analysis - Broj paletnih mjesta	
Summary Statistics for Broj paletnih mjesta	
Count	51
Average	14.5686
Standard deviation	12.3114
Coeff. of variation	84.5061%
Minimum	1.0
Maximum	34.0
Range	33.0
Std. skewness	1.2291
Std. kurtosis	-2.24787

Slika 52. Analiza broja paletnih mjesta

Prosječan broj paletnih mjesta iznosi 14,57 sa standardnom devijacijom 12,31. Koeficijent varijacije je 84,5%. Minimalan izmjeren broj paletnih mjesta je 1, a maksimalan broj paletnih mjesta je 34.




Slika 53. Histogram broja labela

Histogram prikazuje raspodjelu potrebnog broja labela po narudžbi. Najveći slučaj je 57 labela za dobavljača koji je imao najduže vrijeme trajanja preuzimanja robe.

One Variable Analysis - Broj labela	
Summary Statistics for Broj labela	
Count	51
Average	16.0588
Standard deviation	13.1642
Coeff. of variation	81.9749%
Minimum	1.0
Maximum	57.0
Range	56.0
Std. skewness	2.08774
Std. kurtosis	-0.083537


Slika 54. Analiza broja labela

Prosječan broj labela iznosi 16,06 sa standardnom devijacijom od 13,16. Koeficijent varijacije je 81,97% ,minimalan broj labela potreban za jednu narudžbu je 1, a najveća vrijednost 57.




Slika 55. „Box and whisker“ dijagram za tri parametra

Na slici se nalaze box and whisker dijagrami za tri parametra, također je prikazan način na koji su podaci distribuirani s obzirom na druge parametre. Parametri su broj različitih artikala, broj labela i broj paletnih mjesta.




Slika 56. Dijagram raspršenosti trajanja procesa preuzimanja i broja različitih artikala

Dijagram raspršenosti prikazuje na osi apscisi vrijednosti broja različitih artikala, a na osi ordinati vrijednosti za trajanje procesa preuzimanja robe. Vidi se da postoji određena veza između te dvije varijable no prilikom modeliranja jednadžbe koja bi opisala tu vezu treba uzeti u obzir i ostale varijable koje utječu na trajanje procesa preuzimanja.



Slika 57. Dijagram raspršenosti trajanja procesa preuzimanja i broja paletnih mjesta



Slika 58. Dijagram raspršenosti trajanja procesa preuzimanja i broja labela

Prilikom mjerenja procesa preuzimanja promatran je i način rada kontrolora, da li radi slijedno ili paralelno preuzimanje. Ta varijabla nije pokazala utjecaj na vrijeme trajanja procesa te je izostavljena iz modeliranja, problem je i predviđati na koji će način raditi kontrolor ulaza. Također je promatrano da li je bilo kakvih nepravilnosti u vezi robe i potrebe za pisanjem zapisnika. Ta varijabla utječe na vrijeme preuzimanja robe i znatno ga produžuje (desetak minuta). Ne može se predvidjeti da li će biti nepravilnosti, ali može se statistički izračunati kolika je učestalost pojave pisanja zapisnika te ga ukalkulirati u model predviđanja. Promatran je i način pakiranja robe, da li se radi o full pick, mix ili sandwich paleti. Taj podatak ima utjecaj na vrijeme preuzimanja, ali on je već opisan brojem paletnih mjesta i brojem različitih artikala. Na primjer ako se jedna vrsta artikla nalazi na 10 paleta po narudžbi znamo da se radi o full pick paletama i da smo zalijepili 10 labela. A kada se radi o sandwich ili mix paletama nemoguće ih je razlikovati iz narudžbe. No to nije ni potrebno jer broj paletnih mjesta i broj različitih artikala kao ulazne varijable dobro definiraju trajanje procesa kao izlaznu varijablu. Ono što razlikuje full pick od sandwich ili mix palete upravo je broj različitih artikala koji se nalazi na sandwich ili mix paleti, za taj broj različitih artikala zalijepiti ćemo veći broj labela na artikle koji se nalaze na tom paletnom mjestu.

4.9. Izrada modela predviđanja trajanja preuzimanja


Analizirajući sami rad kontrolora ulaza prilikom procesa preuzimanja, to jest analizirajući aktivnosti na koje on gubi vrijeme, zaključak je da broj paletnih mjesta i broj različitih vrsta artikala su jedine varijable koje utječu na vrijeme. Kontrolor ulaza prilikom preuzimanja mora zalijepiti labele na artikle, fizički pregledati stanje robe, količine i rok trajanja te sistemski pomoću skenera unesti podatke u sustav. Što je više paletnih mjesta i različitih vrsta artikala ti procesi će duže trajati. U nastavku je prikazan model za predviđanje trajanja preuzimanja robe (17):


$$\text{MODEL}_{\text{vrijeme preuzimanja}} = f(\text{broj paletnih mjesta}, \text{broj različitih artikala}) \quad (17)$$

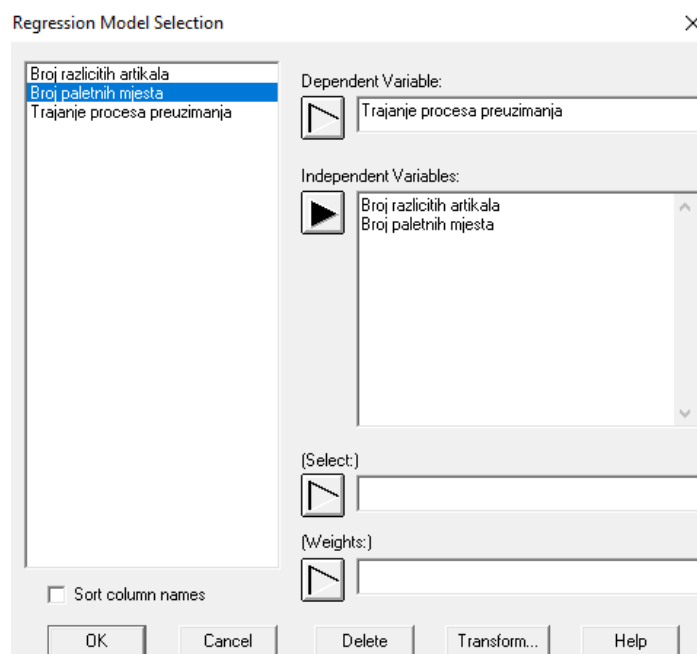
Prije same izrade modela predviđanja potrebno je izbaciti one podatke za koje je zabilježeno pisanje zapisnika. Tijekom snimanja vremena uočeno je da pisanje zapisnika povećava trajanje procesa preuzimanja za 5 do 10 minuta. U tri slučaja je bila potreba za pisanjem zapisnika što čini 5,88% ukupnih podataka. Nakon izbacivanja tih podataka ostaje 48 snimljenih vremena za koje će se pokušati pronaći veza između trajanja procesa preuzimanja, broja paletnih mjesta i broja različitih artikala.

Tablica preuzimanja robe													
Broj otpremnice	Dobavljač	Način preuzimanja robe	Nepravilnosti u vezi robe	Full pick	Sandwich	Mix	Broj različitih artikala	Broj labela	Broj paletnih mjesta	Datum	Vrijeme početka procesa	Vrijeme kraja procesa	Trajanje procesa (minute)
4194000	Dobavljač 1	slijedno	ne	26			11	26	26	10/4/2018	10:18	10:46	28
2018-RTL-000152	Dobavljač 2	slijedno	ne	4			2	4	4	10/4/2018	10:59	11:08	9
87/1/1	Dobavljač 3	slijedno	ne	1			1	1	1	10/4/2018	11:15	11:20	5
2018-104-002725; 2018-182-000007	Dobavljač 4	slijedno	ne	4			3	4	4	10/4/2018	11:31	11:41	10
96	Dobavljač 5	slijedno	ne	16			4	16	16	10/4/2018	12:10	12:31	21
8/18	Dobavljač 6	slijedno	ne	1			1	1	1	10/4/2018	12:44	12:46	2
3623	Dobavljač 7	slijedno	ne	33			4	33	33	10/4/2018	13:12	13:29	17
DA 18013230	Dobavljač 8	slijedno	ne	33			1	33	33	10/5/2018	9:58	10:08	10
30521-07002229-18	Dobavljač 9	slijedno	ne	7			2	7	7	10/5/2018	10:23	10:32	9
18448	Dobavljač 10	slijedno	da(zapisnik)	28			10	28	28	10/5/2018	10:53	11:27	34
00040486	Dobavljač 11	slijedno	ne	1	2		9	9	3	10/5/2018	11:28	11:49	21
10-2018-2770	Dobavljač 12	slijedno	ne	2	1		5	5	3	10/5/2018	12:43	12:58	15
771	Dobavljač 13	slijedno	ne			3	8	8	3	10/5/2018	13:05	13:16	11
50541-07000857-18	Dobavljač 14	slijedno	ne	2			1	2	2	10/10/2018	9:19	9:25	6
80011160	Dobavljač 15	slijedno	ne	3			3	3	3	10/10/2018	9:31	9:39	8
IK0802957	Dobavljač 16	paralelno	ne	4	1		4	5	5	10/10/2018	9:54	10:19	25
20427339	Dobavljač 17	slijedno	ne	1			1	1	1	10/10/2018	10:35	10:43	8
682-1/2018-682/2018	Dobavljač 18	slijedno	ne	6			2	6	6	10/10/2018	10:52	11:06	14
1047/18-1046/18	Dobavljač 19	slijedno	ne	32			4	32	32	10/10/2018	11:28	11:49	21
PRO18015790	Dobavljač 20	slijedno	ne	33			1	33	33	10/10/2018	12:08	12:22	14
2018-ZG-167273-OTP	Dobavljač 21	slijedno	da(zapisnik)	6	9		7	25	15	10/10/2018	12:52	13:36	44
149/18	Dobavljač 22	slijedno	ne	31			1	31	31	10/10/2018	13:06	13:22	16
1902580-183-190	Dobavljač 23	paralelno	ne		3		7	7	3	10/11/2018	15:20	15:34	14
961-2122	Dobavljač 24	slijedno	ne	24			1	24	24	10/11/2018	15:46	15:54	8
6266847803	Dobavljač 25	paralelno	ne	20	12	1	43	57	33	10/11/2018	16:21	17:45	84
5030-ISK1-300	Dobavljač 26	slijedno	ne	33			1	33	33	10/11/2018	17:03	17:17	14
PRO18015915	Dobavljač 27	slijedno	ne	1			1	1	1	10/12/2018	9:18	9:23	5
PRO18015940	Dobavljač 28	slijedno	ne	32			14	32	32	10/12/2018	9:24	10:15	51
9002531033	Dobavljač 29	slijedno	ne	32			18	32	32	10/12/2018	10:23	11:17	54
1729; 6081	Dobavljač 30	slijedno	da(zapisnik)	8	2		10	12	10	10/12/2018	10:32	11:01	29
10-2018-2819	Dobavljač 31	slijedno	ne	2	2		6	6	4	10/12/2018	11:23	11:31	8
2018-ZG-167350-OTP	Dobavljač 32	slijedno	ne	5	4		6	13	9	10/12/2018	11:50	12:07	17
87	Dobavljač 33	slijedno	ne	30			4	30	30	10/12/2018	12:10	12:26	16
A30043138	Dobavljač 34	slijedno	ne		3		10	10	3	10/12/2018	12:19	12:36	17
222	Dobavljač 35	slijedno	ne	7			4	8	7	10/12/2018	12:28	12:42	14
20002318	Dobavljač 36	slijedno	ne	1			1	1	1	10/12/2018	12:33	12:38	5
9002536264; 9002531748	Dobavljač 37	slijedno	ne	26			9	26	26	10/12/2018	12:57	13:24	27
82234528; 82237206	Dobavljač 38	slijedno	ne	24			2	24	24	10/12/2018	13:00	13:18	18
70-891076	Dobavljač 39	slijedno	ne	2	1		5	5	3	10/15/2018	9:16	9:24	8
OTK18-F-04925	Dobavljač 40	paralelno	ne	2	1		4	4	3	10/15/2018	9:44	9:54	10
61/2018	Dobavljač 41	paralelno	ne	6			1	4	6	10/15/2018	10:08	10:18	10
4100014592	Dobavljač 42	paralelno	ne	4	1		3	3	5	10/15/2018	10:17	10:28	11
2018-12733	Dobavljač 43	slijedno	ne	23	1		10	27	24	10/15/2018	10:39	10:56	17
80196401	Dobavljač 44	slijedno	ne	34			3	34	34	10/15/2018	10:46	11:14	28
2.536; 2.535	Dobavljač 45	slijedno	ne	23			4	23	23	10/15/2018	11:24	11:47	23
695/2018	Dobavljač 46	slijedno	ne	11			2	11	11	10/15/2018	12:08	12:20	12
2018-ZG-167446-OTP	Dobavljač 47	slijedno	ne	9	7		6	23	16	10/16/2018	10:56	11:18	22
2100407237	Dobavljač 48	slijedno	ne	28			1	28	28	10/16/2018	11:11	11:22	11
2469	Dobavljač 49	slijedno	ne	4			4	4	4	10/16/2018	11:32	11:52	20
180R0001084	Dobavljač 50	slijedno	ne	12			1	12	12	10/16/2018	11:40	11:50	10
10001-734-6305-18	Dobavljač 51	slijedno	ne	12			6	12	12	10/16/2018	11:56	12:05	9

Slika 59. Podaci za modeliranje

Legenda:  → ulazne varijable (broj paletnih mjesta, broj različitih artikala)

 → izlazna varijabla (trajanje procesa preuzimanja)



Slika 60. Unos varijabli za izradu modela predviđanja

Prvi korak je izbor adekvatnog modela za ovaj skup podataka, kao zavisnu varijablu (dependent variable) odabire se trajanje procesa preuzimanja, a kao nezavisne varijable (independent variables) odabiru se broj različitih artikala i broj paletnih mjesta.

Regression Model Selection - Trajanje procesa preuzimanja

Regression Model Selection - Trajanje procesa preuzimanja

Dependent variable: Trajanje procesa preuzimanja

Independent variables:
A=Broj razlicitih artikala
B=Broj paletnih mjesta

Number of complete cases: 48
Number of models fit: 4

Model Results

		Adjusted		Included
MSE	R-Squared	R-Squared	Cp	Variables
198.783	0.0	0.0	302.652	
43.1115	78.7737	78.3123	30.0059	A
146.502	27.8686	26.3005	207.488	B
26.7969	87.0932	86.5195	3.0	AB


The StatAdvisor

This table shows the results of fitting various multiple regression models to describe the relationship between Trajanje procesa preuzimanja and 2 predictor variables. Models have been fit containing all combinations of from 0 to 2 variables. The statistics tabulated include the mean squared error (MSE), the adjusted and unadjusted R-Squared values, and Mallows' Cp statistic. To determine which models are best according to these different criteria, select one of the Tabular Options.

Slika 61. Analiza varijabli

Iz slike je vidljivo da koeficijent determinacije regresijskog modela $R^2 = 0,8651$ je najveći za obje ulazne varijable. Također je vidljivo da broj različitih artikala u bolje opisuje trajanje

procesa preuzimanja nego broj paletnih mjesta jer za varijablu različitih artikala koeficijent determinacije iznosi $R^2 = 0,7831$ dok kod broja paletnih mjesta on iznosi $R^2 = 0,263$.



Slika 62. Dobiveni model predviđanja i statistički pokazatelji

Pomoću programa „Statgraphics 18“ za zadani skup podataka dobiven je regresijski model (18):

$$Y = 3,4789 + 1,6835 * Z + 0,33848 * X \quad (18)$$

Gdje je:

- $Y \rightarrow$ *trajanje procesa preuzimanja*,
- $Z \rightarrow$ *broj različitih artikala*,
- $X \rightarrow$ *broj paletnih mjesta*.

Koeficijent determinacije modela iznosi $R^2 = 0,8652$ što predstavlja odnos suma kvadrata odstupanja objašnjene regresijskom funkcijom te sveukupne sume kvadrata odstupanja. U pravilu, što je koeficijent determinacije bliži jedinici, model je reprezentativniji. Iznos koeficijenta determinacije može biti u intervalu $0 \leq R^2 \leq 1$. Što je taj koeficijent bliži 1, to

znači da je manja vrijednost sume kvadrata odstupanja ostataka, pa tako i rasipanje vrijednosti oko pravca regresije.

Standardna devijacija odstupanja (residuala) modela iznosi 5,176 dok srednje vrijednost odstupanja (residuala) iznosi 3,686. Koeficijent d dobiven Durbin-Watsonovim testom iznosi $d = 1,885$ za kojeg je P vrijednost je jednaka 0,3405 te ne možemo tvrditi da postoji serijska autokorelacija odstupanja (residuala) sa razinom sigurnosti od 95%.

U nastavku je prikazana matrica korelacije varijabli:

Multiple Regression - Trajanje procesa preuzimanja			
Correlation matrix for coefficient estimates			
	CONSTANT	Broj različitih artikala	Broj paletnih mjesta
CONSTANT	1.0000	-0.2865	-0.6148
Broj različitih artikala	-0.2865	1.0000	-0.2831
Broj paletnih mjesta	-0.6148	-0.2831	1.0000


Slika 63. Matrica korelacija

Tablica najvećih odstupanja (residuala) modela:

Multiple Regression - Trajanje procesa preuzimanja				
Unusual Residuals				
Row	Y	Predicted Y	Residual	Studentized Residual
15	25.0	11.9054	13.0946	2.75
26	51.0	37.8793	13.1207	2.85
40	17.0	28.4375	-11.4375	-2.37


Slika 64. Najveća studentizirana odstupanja (residuali)

Postoje tri studentizirana odstupanja (residuala) u apsolutnom iznosu veća od 2 to jest udaljena od modela za dvije standardne devijacije.



Slika 65. Dijagram odstupanja (residuala)

U nastavku je prikazan dijagram trajanja procesa preuzimanja gdje se na osi apscisi nalaze vrijednosti predviđene modelom, a na osi ordinati izmjerene vrijednosti.



Slika 66. Izmjerena trajanja preuzimanja i trajanja predviđena modelom

Formula za model predviđanja trajanja procesa preuzimanja (19):

$$Y = 3,4789 + 1,6835 * Z + 0,33848 * X \quad (19)$$

Gdje je:

- $Y \rightarrow$ trajanje procesa preuzimanja,
- $Z \rightarrow$ broj različitih artikala,
- $X \rightarrow$ broj paletnih mjesta.

Tablica 12. Usporedba izmjerenog trajanja preuzimanja i dobivenog modelom

Broj različitih artikala	Broj paletnih mjesta	Izmjereno trajanje procesa preuzimanja (minute)	Trajanje procesa preuzimanja po modelu predviđanja	Razlika izmjerenog i modela (minute)	Razlika izmjerenog i modela (%)
11	26	28	30.80	-2.80	-9.99%
2	4	9	8.20	0.80	8.89%
1	1	5	5.50	-0.50	-10.02%
3	4	10	9.88	0.12	1.17%
4	16	21	15.63	5.37	25.58%
1	1	2	5.50	-3.50	-175.05%
4	33	17	21.38	-4.38	-25.78%
1	33	10	16.33	-6.33	-63.32%
2	7	9	9.22	-0.22	-2.39%
9	3	21	19.65	1.35	6.45%
5	3	15	12.91	2.09	13.92%
8	3	11	17.96	-6.96	-63.29%
1	2	6	5.84	0.16	2.68%
3	3	8	9.54	-1.54	-19.31%
4	5	25	11.91	13.09	52.38%
1	1	8	5.50	2.50	31.24%
2	6	14	8.88	5.12	36.59%

4	32	21	21.04	-0.04	-0.21%
1	33	14	16.33	-2.33	-16.66%
1	31	16	15.66	0.34	2.15%
7	3	14	16.28	-2.28	-16.28%
1	24	8	13.29	-5.29	-66.08%
43	33	84	87.04	-3.04	-3.62%
1	33	14	16.33	-2.33	-16.66%
1	1	5	5.50	-0.50	-10.02%
14	32	51	37.88	13.12	25.73%
18	32	54	44.61	9.39	17.38%
6	4	8	14.93	-6.93	-86.67%
6	9	17	16.63	0.37	2.20%
4	30	16	20.37	-4.37	-27.30%
10	3	17	21.33	-4.33	-25.47%
4	7	14	12.58	1.42	10.13%
1	1	5	5.50	-0.50	-10.02%
9	26	27	27.43	-0.43	-1.60%
2	24	18	14.97	3.03	16.84%
5	3	8	12.91	-4.91	-61.40%
4	3	10	11.23	-1.23	-12.28%
1	6	10	7.19	2.81	28.07%
3	5	11	10.22	0.78	7.07%
10	24	17	28.44	-11.44	-67.28%
3	34	28	20.04	7.96	28.44%
4	23	23	18.00	5.00	21.75%
2	11	12	10.57	1.43	11.92%
6	16	22	19.00	3.00	13.66%
1	28	11	14.64	-3.64	-33.09%

4	4	20	11.57	8.43	42.17%
1	12	10	9.22	0.78	7.76%
6	12	9	17.64	-8.64	-96.02%

Multifactor ANOVA - Trajanje procesa preuzimanja					
Analysis of Variance for Trajanje procesa preuzimanja - Type III Sums of Squares					
Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:Broj različitih artikala	4890.48	13	376.191	30.06	0.0000
B:Broj paletnih mjesta	694.651	19	36.5606	2.92	0.0199
RESIDUAL	187.735	15	12.5157		
TOTAL (CORRECTED)	9342.81	47			

All F-ratios are based on the residual mean square error.

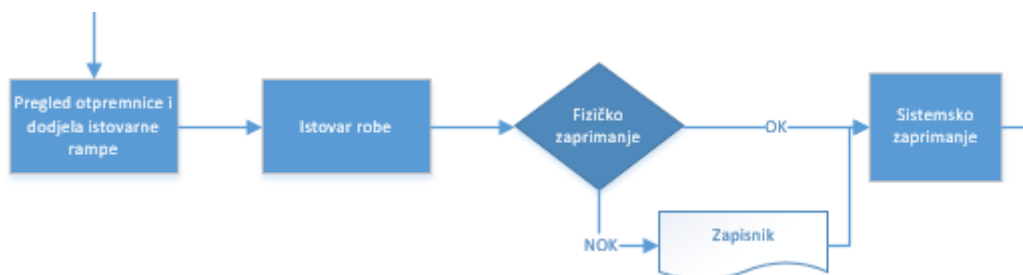
The StatAdvisor
The ANOVA table decomposes the variability of Trajanje procesa preuzimanja into contributions due to various factors. Since Type III sums of squares (the default) have been chosen, the contribution of each factor is measured having removed the effects of all other factors. The P-values test the statistical significance of each of the factors. Since 2 P-values are less than 0.05, these factors have a statistically significant effect on Trajanje procesa preuzimanja at the 95.0% confidence level.

Slika 67. Anova test za ulazne varijable

Anova test utjecaja više faktora na izlaznu varijablu preko F-omjera to jest P vrijednosti testira statističku signifikantnost svakog faktora, P vrijednost za broj paletnih mjesta iznosi 0,0199 što znači da postoji signifikantna veza tog faktora na trajanje procesa preuzimanja sa razinom pouzdanosti od 95% također postoji signifikantna veza između broja različitih artikala i trajanja procesa preuzimanja jer je P vrijednost isto manja od 0,05.

5. MODEL PREDVIĐANJA TRAJANJA PROCESA

Na slici su prikazane one aktivnosti unutar skladišta čija smo vremena trajanja promatrali i koja u najvećoj mjeri utječu na čekanja dobavljača.



Slika 68. Procesi sa najvećim utjecajem na vrijeme

Prvo definiramo ulazne varijable za previđanje vremena:

- $a \rightarrow$ naručena količina jedne vrste artikla po narudžbi (očitavamo iz narudžbe)
- $b \rightarrow$ količina jedne vrste artikla koja stane na jednu paletu (očitavamo iz matičnih podataka)
- $X \rightarrow$ broj paletnih mjesta, računamo (20):

$$X = \frac{a}{b} \quad (20)$$

- $Z \rightarrow$ broj različitih artikala po narudžbi (očitavamo iz narudžbe)

5.1. Pregled otpremnice, dodjela istovarne rampe i dolazak vozača na istovarnu rampu

Vrijeme trajanja ovih aktivnosti je nemoguće unaprijed predviđati jer ovise o ljudskim faktorima, udaljenosti vozača od rampe na koju treba doći, njegovoj sposobnosti brzog parkiranja vozila na istovarnu rampu i slično. Ukupno vrijeme od poziva do dolazaka na rampu je zabilježeno za više slučajeva te je izračunata aritmetička sredina koja iznosi 11 minuta. Vrijeme od 11 minuta je dobiveno analizom rada kontrolora ulaza, gdje je mjereno vrijeme od završetka preuzimanja do početka istovara robe za novu narudžbu te izračunata aritmetička sredina za više slučajeva. Najveće odstupanje je bilo ± 3 minute. To vrijeme možemo smatrati fiksnim prilikom izračuna trajanja svih aktivnosti vezanih uz rukovanje robom.

5.2. Istovar robe

Vrijeme trajanja istovara robe za jednu narudžbu (minute) računa se po modelu (21):

$$Y_{istovar} = 1,3858 + 0,3836 * (\sum_{n=1}^n X_n) \quad (21)$$

gdje je (22):

$$X = \frac{a}{b} = \frac{\text{naručena količina jedne vrste artikla po narudžbi}}{\text{količina jedne vrste artikla koja stane na jednu paletu}} \quad (22)$$

- $X \rightarrow$ broj paletnih mjesta za jednu vrstu artikla,
- $n \rightarrow$ označava broj različitih artikala po narudžbi.

5.3. Preuzimanje robe (fizičko zaprimanje i sistemsko zaprimanje)

Vrijeme trajanja preuzimanja robe (minute) za jednu narudžbu ovisi o značajkama na otpremnici, a računamo ga (23):

$$Y_{preuzimanja} = 3,4789 + 1,6835 * Z + 0,3385 * (\sum_{n=1}^n X_n) \quad (23)$$

gdje je (24):

- $Z \rightarrow$ broj različitih artikala po narudžbi,
- $X \rightarrow$ broj paletnih mjesta za jednu vrstu artikala,

$$X = \frac{a}{b} = \frac{\text{naručena količina jedne vrste artikla po narudžbi}}{\text{količina jedne vrste artikla koja stane na jednu paletu}} \quad (24)$$

- $n \rightarrow$ označava broj različitih artikala po narudžbi.

5.4. Ukupno trajanje procesa

Model za ukupno trajanje procesa za jednu narudžbu unutar depozitnog skladišta (minute) (25):

$$Y = Y_{istovar} + Y_{preuzimanja} + c \quad (25)$$

Gdje je:

- $Y_{istovar}$ → iznos modela predviđanja za istovar jedne narudžbe (minute),
- $Y_{preuzimanja}$ → iznos modela predviđanja za preuzimanje jedne narudžbe (minute),
- c → vrijeme za pregled otpremnice, dodjelu istovarne rampe i dolazak vozača na istovarnu rampu (c = konstanta ~ 11 minuta).

Model predviđanja trajanja svih procesa unutar depozitnog skladišta za jedan dan **(26)**:

$$Y_{jedan\ dan} = \sum_{i=1}^i (Y_i) \quad (26)$$

Gdje je:

- i → broj narudžbi za jedan dan,
- Y → trajanje svih procesa za jednu narudžbu (minute).

6. ZAKLJUČAK

U ovome radu pomoću tehnika mapiranja procesa dan je prikaz redoslijeda procesa unutar depozitnog skladišta. Mapiranje procesa je napravljeno s ciljem utvrđivanja tko je odgovoran za obavljanje određenog procesa i koji procesi najviše utječu na ukupno vrijeme trajanja svih aktivnosti.

Nakon odrađenog mapiranja procesa slijedilo je mjerenje trajanja procesa istovara i preuzimanja jer ti procesi u najvećoj mjeri utječu na čekanja dobavljača u logističko distributivnom centru. Izmjerena su vremena trajanja istovara i preuzimanja za 51 slučaj te na osnovi tih podataka i značajki narudžbe koje se nalaze pohranjene u bazi WMS sustava dobiveni su modeli predviđanja trajanja istovara i preuzimanja robe.

Prvo su utvrđene značajke narudžbe koje utječu na vrijeme trajanja istovara i preuzimanja te je napravljena statistička analiza svih podataka. Za proces istovara pomoću statističkih alata dobiven je model jednostavne linearne regresije gdje broj paletnih mjesta (nezavisna varijabla) utječe na vrijeme trajanja (zavisnu varijablu).

Za proces preuzimanja parametri koji utječu na vrijeme su broj paletnih mjesta i broj različitih artikala. Također je pomoću statističkih alata dobiven model višestruke linearne regresije gdje su nezavisne varijable broj paletnih mjesta i broj različitih artikala, a zavisna varijabla je vrijeme trajanja. Za oba modela je utvrđeno da postoji signifikantna veza između ulaznih parametara i trajanja procesa. Također je napravljena usporedba modela i izmjerenih podataka gdje isto postoji veza između ta dva skupa.

Na kraju je prikazan cjelokupan model za predviđanje trajanja procesa za jednu narudžbu. Taj model se sastoji od pripremnog vremena, vremena za istovar i vremena za preuzimanje. Pod pripremnim vremenom misli se na vrijeme predviđeno za dolazak vozača na istovarnu rampu, to vrijeme je dobiveno izračunom aritmetičke sredine za više slučajeva i smatra se fiksnim.

Treba napomenuti kako su ovi modeli linearne regresije dobiveni za relativno mali skup izmjerenih podataka. Ako bi u budućnosti željeli dobiti kvalitetnije modele trebali bi prikupiti veći broj izmjerenih vremena trajanja procesa. Tako bi se modeli prilagođavali izmjerenim podacima i postajali sve robusniji, a u konačnici precizniji prilikom predviđanja. Ovi modeli mogu poslužiti za bolje razumijevanje i planiranje procesa unutar skladišta, ali i kao dobra baza za daljnje modeliranje pomoću tehnika strojnog učenja.

LITERATURA

- [1] Oluić, Č; Đukić, G.: Predavanja iz kolegija "Tehnička logistika", Zagreb, 2007.
- [2] <http://www.fpz.unizg.hr/prom/?p=2374> (18.11.2018.)
- [3] <http://www.agrokor.hr/hr/brendovi/konzum/>
- [4] Damelio, R.: The Basics of Process Mapping, 2011.
- [5] University of Brighton, Information services : Process mapping with MS Visio 2013. Quick Reference
- [6] Helmers Scott : Microsoft Visio 2010 Step by Step, 2011.
- [7] Tadić, T: Aritmetička sredina i standardna devijacija, Poučak : časopis za metodiku i nastavu matematike, Vol.18 No.69 Ožujak 2017.
- [8] <https://www.pmf.unizg.hr/download/repository/PREDAVANJE11.pdf> (18.11.2018.)
- [9] http://www.unizd.hr/portals/4/nastavni_mat/2_godina/statistika/10_predavanje.pdf (18.11.2018.)
- [10] http://www.ttf.unizg.hr/b-news/news_upload_files/2009/vijest_27-02-2009_49a83133421c0/Statisticki_testovi.pdf (18.11.2018.)
- [11] http://www.bbc.co.uk/bitesize/standard/maths_ii/relationships/boxplots/revision/1/ (18.11.2018.)
- [12] <https://www.statisticshowto.datasciencecentral.com/durbin-watson-test-coefficient/> (18.11.2018.)
- [13] <http://www.zemris.fer.hr/predmeti/statmod/Uvod%20u%20statisticko%20zakljucivanje> (18.11.2018.)

PRILOZI

I. CD-R disc